

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra informatiky

Analýza emailové komunikace

Analysis of Email Communication

Zadání diplomové práce

Student: **Bc. Veronika Uhrová**

Studijní program: N2647 Informační a komunikační technologie

Studijní obor: 2612T025 Informatika a výpočetní technika

Téma: **Analýza emailové komunikace**
Analysis of Email Communication

Jazyk vypracování: čeština

Zásady pro vypracování:

Cílem práce je návrh a implementace systému na analýzu emailové komunikace a vizualizaci výstupů. Systém bude pracovat s reálnými daty a budou navrženy, popsány a vyhodnoceny experimenty s těmito daty. Pro implementaci je doporučen jazyk C#.

1. Rešerše obdobných řešení a analytických přístupů.
2. Návrh a implementace metody na získávání emailových zpráv z vybraného zdroje.
3. Výběr a implementace metod strojového učení a analýzy sítí vhodných pro analýzu emailové komunikace.
4. Návrh a implementace uživatelského rozhraní na analýzu emailové komunikace a vizualizaci analytických výstupů.
5. Dokumentovaná implementace systému.

Seznam doporučené odborné literatury:

- [1] S. Zehnalova, Z. Horak, M. Kudělka. Email Conversation Network Analysis: Work Groups and Teams in Organizations. ASONAM 2015.
- [2] Tang, G., Pei, J., Luk, W. S. (2014). Email mining: tasks, common techniques, and tools. Knowledge and Information Systems, 41(1), 1-31.

Další podle pokynů vedoucího práce.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **doc. Mgr. Miloš Kudělka, Ph.D.**

Datum zadání: 01.09.2017

Datum odevzdání: 30.04.2018



doc. Ing. Jan Platoš, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prehlasujem, že som túto prácu vypracovala samostatne. Uviedla som všetky literárne
pramene a publikácie, z ktorých som čerpala.

V Ostrave, 27.4.2018



Moje podakovanie patrí predovšetkým doc. Milošovi Kudělkovi, Ph.D. za odborné konzultácie a vedenie mojej diplomovej práce.

Abstrakt

Práca študuje aktuálne metódy pre analýzu emailov a detekciu sociálnych rolí v emailových dátach. Nasleduje zoznámenie sa s emailom a jeho popularitou v súčasnosti. Taktiež práca uvádza základné teoretické pojmy a teoretický náhľad na reprezentáciu siete. Uvádzajú sa tu aj základy analýzy sociálnych sietí a detekcie komúnít. Ďalej sa tu píše o frameworku pre detekciu štrukturálnych rolí a ich identifikácie. Ďalšou popísanou metódou pre analýzu sietí je identifikácia *brokerage* rolí. Na základe týchto poznatkov je vytvorená aplikácia pre analýzu a vizualizáciu analytických výstupov. Na záver sú uvedené prevedené experimenty.

Kľúčové slová: email, sociálna sieť, sociálna rola, ego sieť, vizualizácia, brokerage

Abstract

This paper studies current methods for analysing emails and detecting social roles in email data. This is followed by getting acquainted with the email and its popularity nowadays. Also, this thesis presents basic theoretical concepts and a theoretical overview of network representation. Here are also the basics of social networking and community detection. There is also written a framework for structural social roles detection and their identification. Another method for social network analysis is identification of brokerage roles. Based on this knowledge, an application is developed to analyze and visualize analytical outputs. Finally, experiments on the findings of the emailed data are presented.

Key Words: email, social network, social role, ego network, visualization, brokerage

Obsah

Zoznam použitých skratiek a symbolov	10
Zoznam obrázkov	11
Zoznam tabuliek	13
1 Úvod	14
1.1 Motivácia	14
1.2 Vízia	14
1.3 Štruktúra práce	15
2 Súvisiace práce	16
3 Emailová komunikácia	18
3.1 Stručná história emailu	18
3.2 Štruktúra emailu	18
3.3 Emaily v súčasnosti	19
4 Teoretický základ	20
4.1 Graf	20
4.2 Metriky	22
4.2.1 Closeness centrality (Centralita blízkosti)	22
4.2.2 Betweenness centrality (Centralita medzilahlosti)	22
4.2.3 Modularita	23
5 Sociálna sieť	24
5.1 História sociálnych sietí	24
5.2 Analýza sociálnych sietí	24
5.3 Komunity v sociálnych sieťach	25
5.3.1 H2: Predpoklad súvislosti a hustoty	25
5.3.2 Maximálne kliky	26
5.4 Silné a slabé komunity	26
5.5 Detekcia komunit	27
5.5.1 Louvainov algoritmus pre detekciu komunit	27
5.6 Ego sieť	28
6 Metódy analýzy sociálnych sietí	30
6.1 SSRM - Framework pre detekciu štrukturálnych rolí v sociálnych sieťach	30
6.1.1 Rola v kontexte SSRM	30

6.1.2	Roly definované v SSRM	30
6.2	Identifikácia štrukturálnych sociálnych rolí	31
6.2.1	Outsider	31
6.2.2	Leader	32
6.2.3	Outermost	32
6.2.4	Mediator	32
6.3	Brokerage roly	34
6.3.1	Identifikácia brokerage rolí	37
6.3.2	Popis metódy pre identifikáciu brokerage rolí	37
6.4	Analýza ego	38
6.4.1	Veľkosť ego siete	38
6.4.2	Kompozícia ego siete	39
6.4.3	Štruktúra ego siete	39
7	Aplikácia	42
7.1	Špecifikácia	42
7.1.1	Funkčné požiadavky	42
7.2	Návrh	43
7.2.1	Návrhové vzory	44
7.3	Dôležité rozhodnutia	46
7.3.1	Dostupnosť dát	46
7.3.2	Webová vs. desktopová aplikácia	46
7.4	Použité knižnice	47
7.5	Import dát	48
7.6	Implementácia	48
7.6.1	Metóda pre získanie emailových dát	49
7.6.2	Konštrukcia siete	49
7.6.3	Konštrukcia ego siete	49
7.6.4	Triedy pre graf, vrcholy a hrany	50
8	Experimenty	51
8.1	Analýza emailovej komunikácie tímu	51
8.1.1	Príprava a import dát	51
8.1.2	Vizualizácia datasetu	52
8.1.3	Detekcia komunít	53
8.1.3.1	Zmeny komunít v čase	55
8.1.4	Ego sieť	56
8.1.5	Analýza rolí	56
8.1.5.1	SSRM	56
8.1.5.2	Brokerage	57

8.2	Analýza jednotlivca	58
8.2.1	Príprava a import dát	58
8.2.2	Informácie o datasete	59
8.2.3	Detekcia komunit	60
8.2.3.1	Zmeny komunit v čase	61
8.2.4	Ego sieť	62
8.2.5	Analýza rolí	62
8.2.5.1	SSRM	62
8.2.5.2	Brokerage	63
9	Záver	65
9.1	Možnosti rozšírenia a zdokonalenia práce	65
9.1.1	Možné rozšírenia aplikácie	65
	Literatúra	66
10	Prílohy	69

Zoznam použitých skratiek a symbolov

MUA	– Mail User Agent
MTA	– Mail Transfer Agent
IMAP	– Internet Message Access Protocol
XML	– eXtensible Markup Language
SSRM	– Structural social role mining framework
SNA	– Social network analysis

Zoznam obrázkov

1	Akú formu komunikácie preferujete na formálnu komunikáciu?	19
2	Ukážky grafov	20
3	Neorientovaný graf	20
4	Orientovaný graf	21
5	Súvislý (1) a nesúvislý graf (2)	21
6	Úplný graf	21
7	Graf v tvare hviezdy	23
8	Komunity	25
9	Vizualizácia krokov Louvainovho algoritmu.	28
10	Príklad ego siete.	29
11	Príklad brokerage procesu	35
12	Liaison brokerage	35
13	Itinerant brokerage	36
14	Coordinator brokerage	36
15	Gatekeeper brokerage	36
16	Representative brokerage	37
17	Identifikácie <i>brokerage</i> rolí [1]	38
18	Veľkosť ega = stupeň uzla: 6	39
19	Málo štrukturálnych dier vs. veľa štrukturálnych dier.	40
20	Príklad výpočtu redundancie	41
21	UseCase Diagram	43
22	Diagram komponent znázorňujúci jednotlivé komponenty architektúry aplikácie .	44
23	Triedny diagram - Repository pattern	45
24	Model-View-Controller	46
25	Jednoduchá sieť vytvorená s použitím knižnice vis.js	47
26	Príklad použitia knižnice vis.js	47
27	Doménový model	48
28	Príklad konfigurácie emailu pre získanie emailov	49
29	Základné informácie o tímovej sieti.	52
30	Najviac používané emailové domény.	52
31	Vizualizácia siete.	53
32	Vizualizácia komunit v tímovej sieti za celkový čas	54
33	Rozloženie komunit v tímovej sieti za celkový čas	54
34	Rozloženie komunit za prvý časový úsek	55
35	Rozloženie komunit za druhý časový úsek	55
36	Rozloženie komunit za tretí časový úsek	56
37	Počet detekovaných štrukturálnych rôl	57

38	Desať aktérov s najväčším <i>brokerage</i> skórom	57
39	Desať aktérov s najväčším <i>brokerage</i> skórom - graf	58
40	Analýza jednotlivca - základná vizualizácia	59
41	Analýza jednotlivca - základné štatistiky	60
42	Analýza jednotlivca - vizualizácia komunít	60
43	Analýza jednotlivca - vizualizácia komunít v prvom časovom intervale	61
44	Analýza jednotlivca - vizualizácia komunít v druhom časovom intervale	61
45	Analýza jednotlivca - detail detekovaných SSRM rolí	63
46	Desať aktérov s najväčším <i>brokerage</i> skórom	63
47	Desať aktérov s najväčším <i>brokerage</i> skórom - graf	64

Zoznam tabuliek

1	Základné informácie o datasete	51
2	Informácie o členoch tímu	53
3	Informácie o vytvorenej ego sieti	56
4	Informácie o vytvorenej ego sieti	62

1 Úvod

V stručnom úvode je popísaná motivácia, ktorá viedla k vypracovaniu tejto diplomovej práce a vízia toho, čo sa malo dosiahnuť a hrubá štruktúra vypracovaného textu.

1.1 Motivácia

S cieľom uľahčiť používanie emailov a prebádať podnikateľský potenciál emailov, analýza emailov dosiahla pozoruhodný pokrok nielen v oblasti výskumu, ale aj v praxi. Emaily možno považovať za zmiešanú štruktúru obsahujúcu údaje o ľuďoch zo sociálnych alebo aj organizačných aspektov.

Obsah emailu ako textové a netextové dáta

Emaily sú písané viac stručne ako väčšina ostatných dokumentov, často obsahujú hovorové výrazy a skratky, ktoré sa nenachádzajú v bežných slovníkoch, preto štandardné techniky analýzy textov pri práci s emailovými dátami nemusia byť efektívne.

Emaily tiež obsahujú bohatšie typy dát, ako napríklad URL linky, HTML tagy alebo obrázky. Niektoré štúdie jednoducho zjednodušia tieto netextové dátové vstupy v štádiu predpripravovania dát - vymažu ich a ďalej pracujú len s textovými dátami. Tieto netextové dáta však môžu byť užitočné v iných oblastiach, ako napríklad detekcia spamu.

Emaily reprezentujúce ľudské sociálne organizačné vzťahy

Emailová aktivita sama o sebe reprezentuje bohaté ľudské sociálne a organizačné vzťahy, ktoré spájajú ľudí do komunit a komplexných systémov. Porozumenie organizačných štruktúr alebo vzťahov naprieč ľuďmi v organizácii môže byť veľmi užitočné aj v reálnom živote. Hlavné problémy, ktoré sa riešia v analýze emailov sú detekcia spamu, kategorizácia emailov, analýza kontaktov, analýza vlastností emailových sietí a vizualizácia emailov.

1.2 Vízia

Cieľom práce je oboznámiť čitateľa s oblasťou sociálnych sietí a špeciálne s témou analýzy emailových dát a tieto znalosti demonštrovať nad reálnymi emailovými dátami. Pre uskutočnenie tohto cieľa je potrebné naštudovať informácie z oblasti analýzy emailov, reprezentácie emailu v sieti a vizualizácie sociálnych sietí vrátane aktuálnych metód publikovaných v článkoch.

K tomu sa viaže tiež prieskum reprezentácie a konštrukcie emailu ako prvku sociálnej siete.

Ďalej boli vybrané metódy detekcie rolí v sociálnej sieti a navrhnutá aplikácia, ktorá umožňuje analyzovať a vizualizovať analytické výsledky. V tejto aplikácii s jednoduchým a použiteľným užívateľským rozhraním sú implementované vybrané metódy analýzy a je navrhnutá prehľadná vizualizácia vzťahov. Nakoniec je vytvorená analýza tímu podľa emailových dát a porovnanie dvoch prvkov siete a výsledky experimentov sú zrozumiteľne prezentované.

1.3 Štruktúra práce

V prvej kapitole je uvedený prieskum o aktuálnych vedeckých článkoch, ktoré sa zaoberajú analýzou emailov a reprezentáciou emailu v sociálnych sieťach. Ďalej sa čitateľ zoznámí s emailom ako komunikačným prostriedkom a dozvie sa, ako sú na tom emaily s popularitou aktuálne. Potom je uvedený stručný prehľad teórie grafov a definícií určitých pojmov, ktorý je nevyhnutný k porozumeniu ďalších kapitol. V ďalšej kapitole píšem o sociálnych sieťach, ich histórii a analýze sociálnych sietí, komunitnej štruktúre sociálnych sietí a ego sieťach. Neskôr prechádzam k popisu a reprezentácie frameworku pre detekciu štrukturálnych rolí, popisujem sociálne roly definované v

rámci tohto frameworku a následne v ďalšej kapitole referujem pomocou akých metód sa sociálne roly v rámci tohto frameworku identifikujú. Ďalej popisujem ďalšiu metódu pre identifikáciu rolí zo sociálnych sietí, tzv. sprostredkovateľské role (ang. *brokerage*). Na základe všetkých poznatkov práce je navrhnutá aplikácia vhodná k sledovaniu výsledkov navrhnutých metód pre analýzu emailových sietí. Ešte pred záverom sú uvedené výsledky prevedených experimentov týkajúcich sa poznatkami skúmanej sociálnej siete.

2 Súvisiace práce

Pre odhaľovanie vzťahov medzi ľuďmi, skupinami a organizáciami z emailových sietí boli aplikované mnohé techniky a modely analýzy sociálnych sietí. Mnoho štúdií použilo maily spoločnosti *Enron* kvôli nedostatku dostupných veľkých súborov.

Napríklad Diesner, Carley a Frantz v [2] zkonštruovali z mailovej komunikácie spoločnosti Enron orientovaný graf zo vzťahu odosielateľ-prijemca, kde hrany boli vážené frekvenciou mailov, ktoré si medzi sebou poslali v čase. Potom aplikovali techniky analýzy sociálnych sietí. V práci popísali, ako vylepšili originálnu sadu a súčasné zistenia ich investigáciou vďaka analýze sociálnych sietí. Skúmajú dynamiku, štruktúru a vlastnosti organizačnej komunikačnej siete ako aj charakteristiky a vzory komunikačného správania zamestnancov z rôznych organizačných stupňov. Zistili, že počas obdobia krízy sa komunikácia medzi zamestnancami stala viac rôznorodejšia v súvislosti so zavedenými kontaktami a formálnymi rolami. Taktiež počas obdobia kríz, predtým nekomunikujúci zamestnanci sa začali zapájať do vzájomného rozhovoru, takže interpersonálna komunikácia bola intenzívnejšia a sieť sa tým rozširovala. Tieto zistenia poskytli cenný pohľad do organizačnej krízy reálneho sveta, čo môže byť ďalej využité pre validáciu alebo tvorbu teórií a dynamických modelov organizačných kríz a tým to vedie k lepšiemu porozumeniu základných príčin organizačných kríz v organizáciách.

Xiaoyan Fu v [3] prezentoval rôzne metódy pre vizualizáciu emailových sietí. Vizualizácia objavuje komunikačné vzory medzi rôznymi skupinami, zobrazuje analýzu centralít s dôrazom na významné uzly. V práci zkonštruovali 2D vizualizáciu temporálnej emailovej siete, ktorá analyzuje vývoj emailových vzťahov, ktoré sa menia v priebehu času a zobrazenie prostredia pre nájdenie sociálnych kruhov odvodených od siete. Každá metóda bola vyhodnotená s rôznymi datasetmi od výskumnej orgnizácie. Taktiež rozšírili ich metódu pre vizuálnu analýzu siete emailových vírusov.

Ďalej Chapanond, Krishnamoorthy, Yener v [4] použili sieťové metriky a spektrálnu analýzu k analýze či už orientovaného alebo neorientovaného grafu emailov, ktorú skonštruovali zmenou prahovej hodnoty (napr. počtom vymenených emailov medzi užívateľmi). Ich výskum je postavený na vytvorení emailového grafu a štúdiu jeho vlatností či už pomocou teórie grafov alebo technikami spektrálnej analýzy. Grafová teoretická analýza zahŕňa výpočet niekoľkých grafových metrík, ako napríklad rozdelenie podľa stupňov, priemerný pomer vzdialeností, zhlukovací koeficient alebo kompaktnosť emailového grafu. Hodnoty metrík v dátovej sade emailov spoločnosti Enron porovnali aj s inými emailovými dátami.

Jednou z univerzálnejších prác je aj práca autorov Guanting Tang, Jian Pei, and Wo-Shun Luk [5]. Je to stručný prehľad hlavných výskumných snáh o analýzu mailov a popis metód, ktoré sa pri tejto analýze používajú. Nie len čo sa týka analytických alebo implemetnačných úloh, ale aj nástrojov, ktoré nám pri analýze vedia pomôcť. Aby zdôraznili rozdiely medzi analýzou mailov a bežnou analýzou textu, organizujú prieskum do piatich ťažších úloh a to: detekcia nevyžiadanej pošty, kategorizácia emailov, analýza kontaktov, analýza vlastností emailovej siete

a vizualizácia emailov. Tieto úlohy sú vlastne začlenené do rôznych spôsobov používania emailov. Systematicky preskúmajú bežne používané techniky a tiež budujú diskusiu o dostupných softwarových nástrojoch.

Na rozdiel od ostatných prác, Afra Abnar, Mansoureh Takaffoli, Reihaneh Rabbany, Omar R. Zaiane [6] definovali vlastnú metodiku pre analýzu sociálnej siete a definovali *Structural social role mining framework*, ktorý je navrhnutý pre identifikáciu štrukturálnych rolí, pre identifikáciu zmien v sieti a analýzu dopadu zmien na sieť. Definujú základné sociálne roly v sieti a navrhujú metodológie pre ich identifikáciu. Pre identifikáciu týchto rolí využívajú klasické prostriedky analýzy sociálnych sietí a tiež navrhujú nové metriky zahrňujú napríklad Betweenness centrality založenú na komunitách. Z tejto práce som vychádzala pri pomenovaní rolí zo siete a implementovala techniky pre ich identifikáciu.

Ďalšou prácou, ktorou som sa inšpirovala bola práca autorov Kudělka, Horák, Zehnalová [7], ktorá prezentuje analytický nástroj, ktorý bol vytvorený pre analýzu hlbších vzťahov v emailových dátach. Tieto vzťahy zahrňujú vzťahy založené na interakcii viacerých užívateľov v tíme. Analytické metódy popísané v práci sú založené na dvoch faktoroch. Prvým faktorom je kontext, čo je skupina viacerých užívateľov v kombinácii so slovami použitými v komunikácii. Druhým faktorom je časový interval, v ktorom bola začatá komunikácia. Práca prezentuje metódy pre váženie komunikácií, užívateľov a vzťahov, ako aj metód pre hľadanie komunit asociovaných so špecifickým kontextom.

3 Emailová komunikácia

3.1 Stručná história emailu

Za počiatky emailovej komunikácie možno považovať priližne rok 1965, kedy bola správa prenášaná medzi sálovými počítačmi pracujúcich v režime zdieľania času na univerzite *Massachusetts Institute of Technology*.

Od tejto doby prešla emailová komunikácia značným vývojom. Emaily, tak ako ich poznáme dnes, sú definované štandardom špecifikácie RFC2822 a sú prenášané pomocou komunikačných protokolov.

3.2 Štruktúra emailu

Každý email sa skladá z dvoch častí - z tzv. hlavičky (*header*) a tela emailu (*body*).

Hlavička emailu je generovaná automaticky pri vytvorení emailu a sú do nej postupne vkladané informácie zo serverov, cez ktoré správa prechádza (tzv. MTA). Pre bežných užívateľov sú z hlavičky najdôležitejšie tieto údaje: predmet správy, čas odoslania, emailová adresa odosielateľa a prijímateľa. Ostatné údaje emailoví klienti (označovaní tiež ako MUA ¹) väčšinou nezobrazujú.

Pri vytváraní emailu emailovým klientom sú väčšinou do hlavičky vložené tieto záhlavia:

- **Date** - aktuálny čas počítača, ktorý vložil záhlavie
- **From** - adresa odosielateľa
- **Cc** - skratka pre *carbon copy*; adresáti označení ako *CC* dostanú automaticky kópiu správy. Zoznam príjemcov *CC* je viditeľný pre všetkých ostatných príjemcov, na rozdiel od *BCC*.
- **Bcc** - skratka pre *blind carbon copy* - pri odosielaní emailu adresáti označení ako *BCC* dostanú do schránky kópiu emailovej správy, pričom jednotliví príjemcovia nevidia zoznam ostatných príjemcov ako v prípade kópie typu *CC*
- **Priority** - priorita emailu, interpretácia sa líši vzhľadom k MUA
- **Reply-To** - špecifikuje adresu, na ktorú je zaslaná prípadná odpoveď
- **Subjekt** - predmet správy daný užívateľom
- **To** - udáva adresu príjemcu správy
- **Message-Id** - unikátny identifikátor, ktorý je priradený MTA

Telo emailu obsahuje samotné dáta určené pre adresáta.


¹MUA - Mail User Agent, program, ktorý používa užívateľ na rozosielanie a prijímanie emailov (napr. Outlook), tento program komunikuje s MTA (Mail Transfer Agent), ktorý sa stará o prenos emailov v prostredí verejnej siete Internet.

3.3 Emaily v súčasnosti

Emaily teda existujú už niečo cez 50 rokov, ich popularita je však stále veľká vďaka ich efektívnosti, extrémne nízkym nákladom a kompatibilitate s množstvom typov zariadení. Ako jedna z najrozšírenejších typov komunikácie v dnešnej dobe, emaily sú široko rozšírené v každodennom živote. Napríklad, spolupracovníci diskutujú prácu cez emaily, priatelia zdieľajú sociálne aktivity a skúsenosti aj cez emaily alebo veľké spoločnosti distribuujú reklamy práve pomocou emailov.

Aj keď by mnohí tvrdili, že éra emailov už je dávno preč a sú stále viac nahrádzané novými sociálnymi sieťami, nové výskumy ukazujú opak. Napríklad výskum z roku 2016 od spoločnosti Bluecore [8] ukazuje, že email je stále populárny aj u mladších generácií, hlavne na formálnu komunikáciu.

V tomto výskume boli spotrebitelia pýtaní, akú formu komunikácie preferujú pri komunikácii so značkami (internetovými obchodmi, na firemnú komunikáciu a celkovo formálnu komunikáciu). Prevažná časť opýtaných si vybrala email (68%).



Obr. 1: Akú formu komunikácie preferujete na formálnu komunikáciu?

4 Teoretický základ

V tejto kapitole popisujem všetky teoretické pojmy a metódy, ktoré v tejto práci spomínam a používam. V tejto kapitole budem používať matematické názvy podľa kontextu, v ktorom sa budem nachádzať.


4.1 Graf

Definícia 1 *Graf* G (tiež jednoduchý graf alebo obyčajný graf) je usporiadaná dvojica $G=(V,E)$, kde V je neprázdna množina vrcholov a E je množina hrán - množina (niektorých) dvojprvkových podmnožín množiny V . [9]




Obr. 2: Ukážky grafov

Definícia 2 Neorientovaným grafom nazývame dvojicu $G=(V,E)$, kde V je množina uzlov, E je množina jednoprvkových alebo dvojprvkových podmnožín V . [10]




Obr. 3: Neorientovaný graf

Definícia 3 *Orientovaným grafom* rozumieme usporiadanú dvojicu $G = (V,E)$, kde V je množina vrcholov a množina orientovaných hrán je $E \subseteq V \times V$. [9]




Obr. 4: Orientovaný graf

Definícia 4 Hovoríme, že vrchol v je *dosiahnuteľný* z vrcholu u , ak v grafe existuje sled z vrcholu u do vrcholu v . Graf nazveme *súvislý*, ak pre každé dva vrcholy u, v je vrchol v dosiahnuteľný z vrcholu u . V opačnom prípade je graf *nesúvislý*. [9]



Obr. 5: Súvislý (1) a nesúvislý graf (2)

Definícia 5 Graf na n vrcholoch, kde $n \in \mathbb{N}$, ktorý obsahuje všetkých $\binom{n}{2}$ hrán sa nazýva úplný alebo tiež kompletný graf a značí sa K_n . [9]



Obr. 6: Úplný graf

Definícia 6 *Stupeň vrcholu* v grafe G je definovaný ako počet hrán, s ktorými je vrchol incidentný. [9]

$$\deg(u) = |\{e \in E | u \in e\}| \quad (1)$$

Definícia 7 *Ľah* je sled, v ktorom sa neopakujú žiadne hrany a *cesta* je sled, v ktorom sa neopakujú žiadne vrcholy. Uzavrená cesta je cesta, ktorá začína a končí v rovnakom uzle. [9]

4.2 Metriky

V tejto časti popisujem metriky, ktoré v rámci identifikácie rolí v sieti používam. Ďalšie informácie o metrikách, ich praktickom využití a ich ďalších variantách sú zhrnuté v kapitole 6.2.

4.2.1 Closeness centrality (Centralita blízkosti)

Definícia 8 Hodnota closeness centrality vrcholu i je

$$C_i = \frac{1}{l_i} \quad (2)$$

kde $l_i = \frac{1}{n} \sum_j d_{ij}$ je priemerná vzdialenosť vrcholu x_i od ostatných vrcholov, n je počet vrcholov v grafe a d_{ij} je najkratšia cesta medzi vrcholmi x_i a x_j .

Táto centralita meria dôležitosť vrcholu grafu podľa priemernej hodnoty vzdialenosti od všetkých ostatných vrcholov v sieti. Aby dôležité vrcholy mali vyššie číslo, je táto centralita počítaná ako inverzná hodnota tohto priemeru. Vrchol dôležitý podľa tejto metriky môže mať dobrý prístup k informáciám o ostatných vrcholoch alebo naopak môže ostatné vrcholy rýchlejšie ovplyvňovať.


4.2.2 Betweenness centrality (Centralita medziľahlosti)

Definícia 9 Hodnota betweenness centrality vrcholu i je

$$B_i = \sum_{st} \frac{n_{st}^i}{g_{st}} \quad (3)$$

kde g_{st} je počet všetkých najkratších ciest medzi vrcholmi x_i a x_j a n_{st}^i je počet najkratších ciest, ktoré navyše vedú cez vrchol x_i .

Jej hodnota pre vrchol vychádza z počtu najkratších ciest medzi každými dvoma vrcholmi v grafe, na ktorých hodnotený vrchol leží. Pokiaľ medzi vrcholmi v sieti tečú nejaké informácie alebo sa posielajú správy, hodnota tejto metriky vyjadruje, aké množstvo informácií cez daný vrchol prejde. Táto centralita je tiež názorný príklad toho, že každá metrika počíta dôležitosť vrcholu úplne inak. Vrchol s vysokou centralitou medziľahlosti môže mať malý stupeň a nemusí ležať blízko ostatných vrcholov, stačí, keď cez neho prechádza veľa najkratších ciest. To môže nastať, pokiaľ vrchol je most medzi dvoma alebo viacerými komponentami v grafe, v extrémnom prípade pokiaľ je v strede grafu v tvare hviezdy (viď obrázok 7).



Obr. 7: Graf v tvare hviezd

4.2.3 Modularita

Definícia 10 Modularita je definovaná ako

$$Q = \frac{1}{2m} \sum_{i,j} \left[A_{ij} - \frac{d_i d_j}{2m} \right] \delta(c_i, c_j) \quad (4)$$

kde A_{ij} reprezentuje váhu hrany medzi vrcholom i a j , $k_i = \sum_j A_{ij}$ je suma váh hrán pripojených k uzlu i , c_i je komunita ku ktorej je vrchol i priradený, $\delta(u, v)$ je 1 ak $u = v$, inak je 0 a $m = \frac{1}{2} \sum_{i,j} A_{ij}$. [11]

Modularita je metrika, ktorá vychádza z rozdielu medzi počtom existujúcich hrán medzi vrcholmi rovnakého typu a počtom takých hrán v náhodne vytvorenom grafe v pomere ku všetkým existujúcim hranám. Vrcholy rovnakého typu sú tie, ktoré patria alebo majú patriť do rovnakej skupiny alebo triedy (komunity).

5 Sociálna sieť

Sociálna sieť je množina sociálnych subjektov (uzly siete, spravidla jednotlivci alebo organizácie), ktoré sú prepojené jedným, alebo viacerými špecifickými druhmi vzájomnej závislosti, ako sú príbuzenstvo, priateľstvo, vzájomnosť, vízie, odpor, konflikt, obchod a pod. Sociálna sieť z pohľadu teórie grafov je definovaná ako graf $G(V, E)$, kde V je množina entít (uzlov) a E je množina vzťahov (hrán) medzi týmito entitami.

Entity grafu môžu byť rôzne (zákazníci, jednotlivci, webové stránky, bankové účty, creditné karty, produkty). Nie je pravidlom, že len sociálna sieť ako ju pozná mnoho ľudí je sociálnou sieťou aj v exaktnom slova zmysle.

5.1 História sociálnych sietí

Pod pojmom sociálna sieť si väčšina ľudí v dnešnej dobe predstaví služby ako *Facebook*, *Twitter* a pod. Tento pojem ale vznikol dlho pred vznikom internetu a dnešných sociálnych sietí. Prívlastok sociálny, ktorý sa v dnešnej dobe často vynecháva, je dôsledkom pôvodu analýzy sociálnych sietí. V druhej polovici 20. storočia sa simultánne v rôznych oblastiach skúmania vzťahov a chovania objavil nový pohľad na vzťahy medzi sociálnymi jednotkami a to ako na sieť, graf. Preto prví predstavitelia analýzy sociálnych sietí boli pôvodne sociológovia alebo psychológovia (napríklad Moreno, Cartwright, Newcomb, Bavelas) a antropológovia (Barnes, Mitchell). Prvé použitie termínu "sociálna sieť" sa pripisuje Barnesovi (1954).

V 30. rokoch 20. storočia psychiater Moreno rozvíjal sociometriu, predchodcu dnešnej analýzy sociálnych sietí. Vypytoval sa ľudí na priateľské vzťahy a skúmal, ako tieto vzťahy ovplyvňujú ich chovanie. Potom vynášiel tzv. *sociogram*, čo je diagram reprezentujúci ľudí ako body a vzťahy medzi ľuďmi ako úsečky, teda dnešnú sociálnu sieť. Tento pojem sa ale začal používať až neskôr. Pomocou neho hľadal výrazné a izolované osoby v spoločnosti.

Zhruba o 20 rokov neskôr antropológ Barnes začal skúmať, ako ovplyvnia vzťahy medzi ľuďmi nielen jednotlivcov, ale aj spoločnosť ako celok a zameral sa na štúdium skupín, komunít. Na práci Barnes a jeho spolupracovníkov naviazala na Univerzite na Harvarde skupina vedená Harrisom Whitom. Tá začala budovať matematickú teóriu okolo dôležitejších pojmov zo sociálnych vied a umožnila tieto javy matematicky vyjadriť, merať a modelovať.

V druhej polovici 20. storočia sa rozšírilo povedomie o sociálnych sieťach a metódy sa začali používať aj v ďalších oboroch ako ekonómia, biológia, doprava atď.

5.2 Analýza sociálnych sietí

Analýza sociálnych sietí je interdisciplinárna veda s koreňmi v sociológii, psychológii, štatistike a teórii grafov. Analýza sociálnej siete chápe sociálnu sieť ako systém prepojenia uzlov (individuálnych aktérov) prostredníctvom hrán (ich vzťahov). Možno teda povedať, že nadväzuje na matematickú teóriu grafov a metódy sieťovej analýzy. Výsledkom analýzy môže teda byť mapa

graficky znázorňujúca všetky prvky skúmaného sociálneho systému a ich vzťahy (resp. vybrané charakteristiky jednotlivých vzťahov vyjadrené vhodným spôsobom graficky). Charakteristikou môže byť napríklad vzájomná sympatia či antipatia alebo pravidelná vzájomná komunikácia alebo spolupráca.

Analýza sociálnych sietí vystupuje napríklad ako základná technika v rámci modernej sociológie, antropológie, sociálnej lingvistiky, geografie, sociálnej psychológie, ekonómie a biológie rovnako ako populárna téma pre výskum.

5.3 Komunity v sociálnych sieťach


Sociálne siete sú riedke grafy zložené z hustých podgrfov. Tieto husté podgrafy sú nazývané komunity. Najčastejšia definícia komunity: *Komunita je zhluk uzlov, kde počet vnútorných hrán v komunite je väčší ako počet vnokajších hrán – mimo komunity* [12]. Komunity sú v [13] popísané podľa dvoch hypotéz (H2), ktoré popisujem v nasledujúcich podkapitolách.

5.3.1 H2: Predpoklad súvislosti a hustoty

Komunity sú lokálne husto prepojené subgrafy v sieti. Toto očakávanie sa opiera o dva odlišné predpoklady:

Predpoklad súvislosti

Každá komunita odpovedá súvislému podgrafu, podobne ako subgrafy tvorené oranžovými, zelenými alebo fialovými uzlami na obrázku 8. V dôsledku toho, ak sa sieť skladá z dvoch izolovaných komponent, každá komunita je obmedzená len na jednu komponentu. Táto hypotéza tiež naznačuje, že na tejto zložke sa komunita nemôže skladať z dvoch subgrfov, ktoré nemajú vzájomnú väzbu. V dôsledku toho oranžové a zelené uzly tvoria samostané komunity. [13]



Obr. 8: Komunity

Predpoklad hustoty

Uzly v komunite pravdepodobne združujú viac ďalších členov komunity než uzly v iných komunitách. Oranžové, zelené a fialové uzly toto očakávanie spĺňajú. [13]

Inými slovami, všetci členovia komunity musia byť dosiahnuteľní cez ostatných členov tej istej komunity (súvislosť). V tom istom čase predpokladáme, že uzly, ktoré patria do komunity

majú vyššiu pravdepodobnosť spájať ostatných členov tejto komunity ako uzly, ktoré do tejto komunity nepatria (hustota). [13]

5.3.2 Maximálne kliky

Jeden z prvých článkov o štruktúre spoločenstva publikovaný v roku 1949, definoval komunitu ako skupinu jednotlivcov, ktorej členovia sa navzájom poznajú [14]. V teoretických termínoch grafov to znamená, že komunita je komplexný subgraf alebo klika. Klika automaticky uspokojuje H2 - je to spojený subgraf s maximálnou hustotou väzieb. Aj keď zobrazenie komunit ako kliky má niekoľko nevýhod:

- Zatiaľ čo v sieťach sú časté trojuholníky, väčšie kliky sú vzácne.
- Požiadavka na to, aby komunita bola kompletný subgraf, môže byť príliš restriktívna a chýba mnoho ďalších legitímnych komunit. [13]

5.4 Silné a slabé komunity

Zvažujme súvislý subgraf C s N_c uzlami v sieti. Vnútorň stupeň k_i^{int} uzla i je počet prepojení, ktoré sa pripojujú k iným uzlom v C . Externý stupeň k_i^{ext} je počet spojení, ktoré sa pripojujú k zvyšku siete. Ak je $k_i^{ext} = 0$, každý sused i je vnútri C a preto C je dobrá komunita pre uzol i . Ak je $k_i^{int} = 0$, musí byť uzol priradený k inej komunite. Tieto definície nám umožňujú rozlíšiť dva druhy spoločenstva. [13]

Silná komunita

C je silná komunita, ak každý uzol vnútri C má viac spojení vo vnútri komunity ako s celou sieťou [15], [16]. Konkrétne, podgraf C tvorí slabú komunitu ak pre každý uzol $i \in C$:

$$k_i^{int}(C) > k_i^{ext}(C) \quad (5)$$

Slabá komunita

C je slabá komunita, ak celkový vnútorný stupeň subgrafu prekračuje svoj celkový externý stupeň [16]. Konkrétne subgraf C tvorí slabú komunitu ak:

$$\sum_{i \in C} k_i^{int}(C) > \sum_{i \in C} k_i^{ext}(C) \quad [13] \quad (6)$$

5.5 Detekcia komunít

Detekcia komunít je proces identifikácie zhlukov uzlov siete silne prepojených medzi sebou a menej silne prepojených so zvyškom siete. Detekcia komunít v grafoch má za cieľ identifikovať moduly a ich prípadnú hierarchickú organizáciu.

Problém detekcie komunít vyžaduje rozdelenie siete do komunít husto prepojených uzlov, pričom uzly patriace do odlišných komunít sú len slabo prepojené. Vyhľadávanie rýchlych algoritmov pritiahlo veľký záujem vďaka zvyšujúcej sa dostupnosti rozsiahlych sieťových dátových súborov a vplyvu sietí na každodenný život. Môžeme rozlišovať niekoľko typov algoritmov detekcie komunít: *rozdeľovacie* (ang. *graph partitioning*) algoritmy - tie detekujú slabé spojenia vnútri siete a postupne ich odstraňujú zo siete, *algomeratívne* algoritmy - zlučujú podobné uzly a postupne komunity podľa spoločných črt a *optimalizačné* metódy sú postavené na maximalizácii účelovej funkcie. Kvalita rozdielov vyplývajúcich z týchto metód sa často meria modularitou. Je to hodnota v intervale od -1 do 1, ktorá meria hustotu spojov vnútri komunít v porovnaní s prepojeniami medzi komunitami. [11]

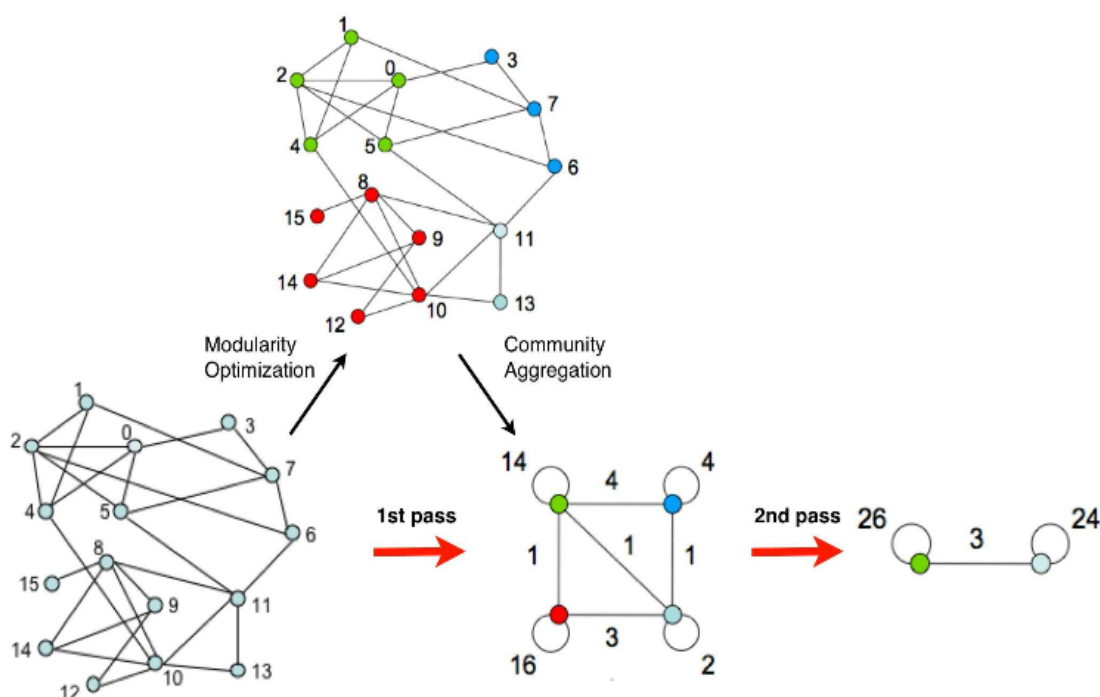
5.5.1 Louvainov algoritmus pre detekciu komunít

Veľmi obľúbeným a rýchlym algoritmom pre detekciu komunít je Louvainova metóda, ktorú navrhli Blondel, Guillaume, Lambiotte a Lefebvre [17]. Je to jednoduchá metóda pre extrakciu komunitnej štruktúry veľkých sietí. Je to heuristická metóda, ktorá je postavená na optimalizácii modularity. Je preukázané, že prekoná všetky ostatné známe metódy detekcie komunít, pokiaľ ide o čas výpočtu. Navyše kvalita detekovaných komunít je veľmi dobrá.

Výpočet algoritmu je rozdelený do dvoch fáz, ktoré sa iteratívne opakujú. Predpokladajme, že začíname s váženou sieťou s N uzlami. Pokiaľ ide o neváženú sieť, základná hodnota váhy je 1. Ako prvé označíme každý uzol siete inou komunitou. Takže v tomto prvotnom rozdelení je toľko komunít, ako je uzlov. Potom pre každý uzol i uvažujeme susedov j a vyhodnotíme prírastok modularity, ktorý by nastal, ak z sme odstránili uzol i z jeho komunity a priradili by sme ho do komunity uzla j . Uzol i je potom vložený do komunity, pre ktorú je tento prírastok najvyšší, ale len ak je tento prírastok kladný. Ak nie je možný žiadny kladný prírastok, uzol i ostáva vo svojej komunite. Tento proces je aplikovaný opätovne a sekvenčne pre všetky uzly kým sa nedosiahne žiadne zlepšenie a prvá fáza je kompletná. Prvá fáza končí, keď je dosiahnuté lokálne maximum modularity, keď žiadny uzol už nemôže zlepšiť modularitu. Je taktiež dôležité, že výstup algoritmu závisí na postupe, v ktorom sú uzly brané do úvahy. Výsledky algoritmu

ale naznačujú, že usporiadanie uzlov nemá významný vplyv na získanú modularitu. Zoradenie však môže ovplyvniť výpočtový čas. Problém pri výbere objednávky preto stojí za to študovať, pretože by mohol poskytnúť dobrú heuristiku na zvýšenie výpočtového času.

Druhá fáza algoritmu spočíva vo vytvorení novej siete, ktorej uzly sú komunity nájdené počas prvej fázy algoritmu. K tomu, aby sa nová sieť vytvorila, váhy spojení medzi novými uzlami sú dané sumou váh prepojení medzi uzlami korešpondujúcich dvoch komunít. Spojenia medzi uzlami tej istej komunity vedú k slučkám v novej sieti. Keď je druhá fáza kompletná, je možné znova aplikovať prvú fázu algoritmu na výslednú väznú sieť a proces opakovať. Pri konštrukcii sa počet komunít znižuje pri každom priechode. Proces sa opakuje, kým nie sú žiadne ďalšie zmeny a dosiahne sa maximálna modularita.




Obr. 9: Vizualizácia krokov Louvainovho algoritmu.

Každý priechod je tvorený dvomi fázami: prvá, kde je modularita optimalizovaná tým, že umožňuje len miestne zmeny komunít a druhá, kde nájdené komunity sú agregované tak, aby bolo možné vytvoriť sieť komunít. Priechody sú opakované iteratívne kým nie je možný žiadny nárast modularity.

5.6 Ego sieť

Ego sieť je sieť tvorená uzlami, ktoré sa nazývajú aj *alter* uzlami, ktoré sa formujú okolo určitého uzla, ktorý sa nazýva *ego*. Toto ego sa niekedy zo siete vynecháva za účelom analýzy zmien siete.

To závisí od danej analýzy [18]. Ego je individuálny ústredný uzol. Sieť môže mať toľko ég, koľko má uzlov. Egá môžu byť osoby, skupiny, organizácie alebo celé spoločnosti.



Obr. 10: Príklad ego siete.

6 Metódy analýzy sociálnych sietí

6.1 SSRM - Framework pre detekciu štrukturálnych rolí v sociálnych sieťach

Afra Abnar, Mansoureh Takaffoli, Reihaneh Rabbany, Osmar R. Zaiane [6] definovali *Structural social role mining framework*, ktorý je navrhnutý pre identifikáciu štrukturálnych rolí, pre identifikáciu zmien v sieti a analýzu dopadu zmien na sieť. Definujú základné sociálne roly v sieti: *Leader, Outermost, Mediator, Outsider*.

Pozn: Jednotlivé roly z anglického jazyka neprekladám a preberám ich pomenovania z [6].

6.1.1 Rola v kontexte SSRM

Sociálna rola je síce základný sociologický pojem, ale stále neexistuje žiadny konsenzus v jej definícii. Podľa SSRM je rola je považovaná za pozíciu jednotlivca v spoločnosti. Informácie o sociálnej sieti sú kategorizované do štrukturálnych a neštrukturálnych vlastností. Štrukturálne vlastnosti sú príbuzné ku konštrukcii grafu ako sú spojenia entít (hrany), štruktúra susedov a pozícia entity v tejto štruktúre. Ale neštrukturálne vlastnosti sú ostatné informácie, ktoré neodrážajú konštrukciu grafu ako atribúty entít a spojení.

Definícia 11 *Rola* (podľa SSRM) entity v sieti je to, ako sa entita správa voči ostatným a jej vplyv na atribúty a štruktúry ostatných entít.

6.1.2 Roly definované v SSRM

Ludské siete sú vnútorne zložené z viacerých komunít. V sociálnej sieti s viacerými komunitami, vlastnosti uzlov kolíšu podľa toho, či je existencia komunít dostatočná alebo zanedbateľná. Z pohľadu sociálnej siete, uzol môže byť centrom celej siete, ale nie centrom v jeho komunite. SSRM sa teda zameriava na štúdium sociálnych sietí s predpokladom existencie komunít v sieti, ako jej základnej črty.

V sociálnych sieťach môžu byť komunity explicitné alebo implicitné. Explicitné komunity sú postavené nezávisle na jej členoch a sú založené na množine pravidiel. V tomto prípade, ľudia sa stanú členmi tejto komunity častejšie až po zformovaní komunity. Zamestnanci firmy alebo študenti sú príkladom dvoch explicitných komunít. Zatiaľ čo formácia implicitných komunít principiálne závisí na jej členoch a spojeniach. Tým pádom neexistuje žiadna externá podmienka na vybudovanie implicitnej komunity. Implicitné komunity sú postavené postupne ako sa ľudia spoločne stretávajú. Napríklad, skupina priateľov, v ktorej nie je žiadne pravidlo pre správanie sa jednotlivcov, je príklad implicitnej komunity. V oboch prípadoch explicitnej aj implicitnej komunity, by mali existovať aj špeciálni jednotlivci, ktorí sú pre komunitu dôležitejší ako ostatní. Napríklad v školskej triede je to učiteľ alebo inštruktor. Pre firmu to je manažér vo vedení a pre skupinu priateľov je to zase človek, ktorého komunikačné schopnosti prinášajú ďalších členov

alebo posilňujú vzťahy medzi tými stálymi. Títo dôležití jednotlivci sú ešte viac výrazní, keď je komunita obrovská.

Podľa toho SSRM framework definuje pre jednotlivcov v sociálnej sieti určité roly podľa ich vzťahov a pozícií v komunitách až po ich interakcie s ostatnými jednotlivcami. Z perspektívy komunit, v sieti existujú jednotlivci niekoľkých typov:

- so žiadnym vzťahom ku nejakej komunite
- so spojením s viacerými komunitami
- dôležití členovia komunity
- bežní členovia komunity, ktorí formujú väčšinu
- nedôležití členovia komunity, ktorí nemajú na komunitu pozorovateľný efekt

Na základe týchto poznatkov SSRM definuje štyri základné roly - **leader**, **mediator**, **outermost** a **outsider**.

Definícia 12 *Leader* je mimoriadny jednotlivec v zmysle centrality alebo významu v každej komunite. V reálnom svete môže tento člen zastávať pozície ako veliteľ, riaditeľ, manažér, vládca, prezident, vedúci tímu, administrátor atd.

Definícia 13 *Outermost* patrí do časti menej dôležitých jednotlivcov v každej komunite, ktorých vplyv a efekt na komunitu sú nižšie ako vplyv väčšiny členov komunity. Miesta, kde sa môže outermost v sieti nachádzať sú periférie alebo hranice grafu.

Definícia 14 *Mediator* je jednotlivec, ktorý zohráva dôležitú rolu v spojení komunit medzi sebou. Funguje ako mostík medzi odlišnými komunitami. Rolu *mediator* zastávajú napríklad vyjednávači, sprostredkovatelia alebo aj rozbočovače v sieti.

Definícia 15 *Outsider* je jednotlivec, ktorý nie je spojený so žiadnou komunitou v sieti. Buď má takmer rovnaké prepojenie k rôznym komunitám alebo má len veľmi slabé väzby na komunity.

6.2 Identifikácia štrukturálnych sociálnych rolí

Majúc sieť s komunitami explicitne známymi alebo extrahovanými nejakým detekčným algoritmom, následne popisujem metodológie pre identifikovanie definovaných štrukturálnych rolí.

6.2.1 Outsider

Najviac priamočiarou rolou pre identifikáciu je outsider. Je to jednotlivec, ktorý v sieti nepatrí do žiadnej komunity. Identifikácia tejto roly je tak priamočiara. SSRM detekuje jednotlivca ako *outsider* len vtedy, keď nie je prepojený žiadnou hranou so zvyškom siete.

6.2.2 Leader

Leader je v každej komunite výnimočný centrálny člen. Pre identifikovanie takýchto uzlov SSRM využíva metriku *closeness centrality* (definovaná v kapitole 4.2.1).

Pre každý uzol sa stanoví hodnota *closeness centrality*. Hodnoty *closeness centrality* sú blízke normálnemu rozdeleniu, v ktorom 95% populácie dát patrí do intervalu $[\mu - 2 \cdot \sigma, \mu + 2 \cdot \sigma]$ (v [6] predpokladajú normálne rozdelenie).

Leadri ležia na hornom chvoste distribučnej funkcie, a teda horný interval použijeme pre identifikovanie leadrov. A teda uzly, ktoré majú väčšiu hodnotu *closeness centrality* ako krajná hodnota tohto intervalu, sú identifikovaní ako leadri.

6.2.3 Outermost

Podobne ako pri role *Leader* pre identifikovanie outermostov sa využíva metrika *closeness centrality*. Outermosti budú ležať však na spodnom chvoste distribučnej funkcie *closeness centrality*.

A tak teda uzly, ktoré majú hodnotu *closeness centrality* nižšiu ako $[\mu - 2 \cdot \sigma]$, patria k role *outermost*.

6.2.4 Mediator

Rolu mediator zastávajú tí jednotlivci, ktorí spájajú viacero komunít a sú tzv. spojmy medzi komunitami.

Pre identifikáciu mediátorov sa definujú metriky založené na metrike *betweenness centrality* a to: *LBetweeness* a *CBetweeness* (definované nižšie, definícia 17 a 18) a ďalej metriky, ktoré vyjadrujú koľko rozdielnych komunít uzol spája: *DSCount* a *DSPair*.

LBetweeness

Definícia 16 *LPath* je množina všetkých najkratších ciest medzi lídrami dvoch rozdielnych komunít.

$$LPath = l | startNode(l) \in leaderSet(c_i) \wedge endNode(l) \in leaderSet(c_j) \wedge c_i \neq c_j \quad (7)$$

Definícia 17 *LBetweeness* je počet jedinečných *LPath* ktoré obsahujú *v*. Ak pre každú cestu *p* $x \in LPath$ definujeme $I_l(p, v) = 1$ ak *v* leží na *p*, inak $I_l(p, v) = 0$ potom:

$$LB(v) = \sum_{p \in LPath} I_l(p, v) \quad (8)$$

CBetweeness

Definícia 18 Ak s_p a e_p označujú štartovací a koncový uzol najkratšej cesty p , c_v označuje komunitu, do ktorej uzol v patrí a $CPaths = \{p | c_{s_p} \neq c_{e_p}\}$ je množina všetkých najkratších ciest, ktoré spájajú rozdielne komunity, tak *CBetweeness* definujeme ako:

$$CB(v) = \frac{1}{2} \sum_{p \in CPaths} I_p(p, v) \quad (9)$$

kde $I_p(p, v) = 1$ ak v leží na ceste p a $I_p(p, v) = 0$ keď neleží.

Normalizovaná verzia CBetweeness

Pravdepodobnosť nájdenia viac viditeľných mediátorov vo väčších komunitách je väčšia v porovnaní s menšími komunitami. Táto situácia sa stáva, pretože vo väčších komunitách je pochopiteľne viac uzlov, čo vedie k viacerým najkratším cestám medzi nimi. Pre kompenzáciu tohoto efektu je definovaná normalizovaná verzia *NBC*:

$$NBC(v) = \frac{1}{2} \sum_{p \in CPaths} \frac{I_p(p, v)}{\min(|c_{s_p}|, |c_{e_p}|)} \quad (10)$$

Navrhnuté metriky *CBetweeness* a *LBetweeness* sú nevyhnutné pre identifikovanie mediátorov, ale nie sú dostatočné. Napríklad pre sieť pozostávajúcu z desiatich komunít a dvoch mediátorov M_1 a M_2 , kde oba ležia na sto najkratších cestách medzi komunitami majú oba rovnaké hodnoty *CBC*. Kdežto M_1 spája dve rozdielne komunity, kým M_2 spája všetkých 10. Pri takomto scenári M_2 spája komunity viac globálne a mal by byť skôr posudzovaný ako mediátor ako M_1 . A tak *SSRM* definuje tzv. metriku **skóre rozmanitosti**, ktorá označuje rozdielne komunity, ktoré sú prepojené cez uzol.

Skóre rozmanitosti

Táto metrika ukazuje koľko rozdielnych komunít je spojených cez špecifický uzol v . Túto metriku definujeme v dvoch variantach: *DSCount* (z ang. diversity score count) a *DSPair* (z ang. diversity score pair).

Definícia 19 *DSCount* je definovaný ako počet rozdielnych komunít, ktoré sú spojené daným uzlom. Nech $I_d(c_i, v) = 1$ ak $\exists p \in CPaths : s_p \in c_i \wedge v \in p$. Potom *DSCount* uzla v je definovaný ako:

$$DSCount(v) = \frac{1}{2} \sum_{c_i} I_d(c_i, v) \quad (11)$$

Definícia 20 DS_{pair} je počet párov komunít, ktoré majú najmenej jednu najkratšiu cestu medzi ich členmi, ktoré prechádzajú uzlom v .

Definujeme $I_d(c_i, c_j, v) = 1$ ak $\exists p \in CPaths : s_p \in c_i \wedge e_p \in c_j \wedge v \in p$

$$DS_{pair}(v) = \frac{1}{2} \sum_{c_i} \sum_{c_j \neq c_i} I_d(c_i, c_j, v) \quad (12)$$

Aj keď viac mediátorov môže mať rovnaké hodnoty jednotlivých metrík, môžu sa odlišovať napríklad v počte komunít, ktoré spájajú. SSRM to berie do úvahy a definuje tzv. *mediacy score* ako násobok normalizovanej CBetweeness a skóra rozmanitosti:

$$MS(v) = NCB(v) \cdot DS_{count}(v) \quad (13)$$

6.3 Brokerage roly

Pozn: Pomenovanie brokerage (slovensky sprostredkovateľstvo) neprekladám a preberám z [19].

Jednoducho povedané, *brokerage* sa vyskytuje tam, keď jeden aktér siete poskytuje most medzi dvoma inými aktérmi, ktorí medzi sebou inak prepojení nie sú. Koncept *brokerage* rôl bol použitý vo veľmi veľa iných kontextoch, záleží len na jeho formalizácii. Aj keď je *brokerage* tradične konceptualizovaný ako dynamický fenomén, identifikácia *brokerage* rôl sa často využíva aj v oblasti statických spoločenských vzťahov.

Jedným známym kontextom pre *brokerage* je prípad obchodných vzťahov. V tomto prostredí, títo jednotlivci alebo organizácie, politické entity, ktorí boli schopní previezť tovar z jedného miesta na druhé a kontrolovať ich rozšírenie, zohrávali kľúčovú rolu v udržiavaní obchodu na regionálnej a kontinentálnej úrovni. Sprostredkovaním kontaktov medzi vzdialené tretie strany (ktoré si nemôžu vymeniť informácie inak), títo aktéri povolili uvoľnenie kritických, priestorovo lokalizovaných zdrojov naprieč rozľahlým územím, čo usnadňovalo rast zložitejších spoločností. Kým *brokerage* vo výmenných sieťach má dôležité systematické následky, jeho efekt na individuálnej úrovni bol oceňovaný viac intenzívne sociológmi (napr. v [19] [20] [21]).

Je zrejmé, že *brokerage* sa môže vyskytnúť v mnohých nastaveniach a povaha *brokerage* procesu samotného sa líši od kontextu. V širšom zmysle tento proces spadá pod tri triedy - *transfer brokerage*, v ktorom *broker (ego)* vedie informácie a iné zdroje od jedného jednotlivca k druhému, ktorí nie sú priamo prepojení. Potom *matchmaking brokerage*, v ktorom ego predstavuje alebo inak umožňuje spojenie jedného jednotlivca k druhému a nakoniec *coordination brokerage*, v ktorom ego usmerňuje kroky ostatných a tak vyrieši svoje závislosti bez toho, aby museli byť priamo prepojení.

Brokerage je stav alebo situácia, v ktorej účastník spája inak neprepojených účastníkov alebo zaplňuje medzery alebo diery v sieti. [19] Na obrázku 11 je *broker* alebo aj *spostredkovateľ* zastúpený čiernym uzlom, ktorý vyplňuje dieru v sieti alebo spojuje ostatných jednotlivcov reprezentovaných bielymi uzlami, ktoré predtým neboli navzájom prepojené priamo.




Obr. 11: Príklad brokerage procesu

Broker môže prepojiť oddelené oblasti siete sociálnymi, ekonomickými alebo politickými aspektami a preto je jediný, kto má prístup k ceneným informáciám a zdrojom z rôznych oblastí siete. *Brokerage* je mechanizmus, ktorý umožňuje izolovaným či neprepojeným členom siete zdieľať informácie a zdroje a ekonomicky, politicky či spoločensky ovplyvňovať. [22]

Práve kvôli spojeniu a kontrole nad jedinečnými informáciami a zdrojmi medzi neprepojenými účastníkmi siete má aktér, ktorý zohráva rolu sprostredkovateľa (*broker*) v sieti väčší prístup k informáciám a zdrojom v porovnaní s tými, ktorí sprostredkovateľmi nie sú. *Broker* (sprostredkovateľ) môže ťažiť z tejto kontroly nad informáciami a zdrojmi, môže sa stať silnejší v sieti a môže vykazovať zvýšenú efektivitu vo svojej práci. [22]


Detailnejšiu kategorizáciu *Brokerage* rôl predstavili Gould a Fernandez [19], kde predstavili koncept *brokerage* typológie. Táto typológia delí *brokerage* do piatich typov na základe smeru toku informácií - tokov v sieti - a rozdeľuje aktérov do vzájomne sa vylučujúcich skupín, tried alebo organizácií. Typy sprostredkovateľov sú *liaison*, *itinerant*, *coordinator*, *gatepeeker* a *representative*.

Definícia 21 *Liaison* je *broker* (B) spojenie medzi dvoma akérmi (A a C), ktorí patria do inej skupiny (komunity) a *broker* nie je súčasťou ani jednej tejto skupiny (komunity). Vid' obrázok 12.




Obr. 12: Liaison brokerage

Definícia 22 *Itinerant* je *broker* (B) spojenie medzi dvoma akérmi (A a C), ktorí patria do rovnakej skupiny (komunity), pričom on do tejto skupiny (komunity) nepatrí. *Itinerant* je tiež nazývaný ako *Consultant broker*, pretože sa chová ako konzultant pre oboch nespojených aktérov tej istej skupiny (komunity). Vid' obrázok 13.




Obr. 13: Itinerant brokerage

Definícia 23 Aktér (B) je *coordinator broker*, ak všetci traja aktéri (A,B,C) patria do rovnakej skupiny (komunity) a sprostredkovanie informácií a zdrojov sa deje v rámci skupiny (komunity). Viď obrázok 14.




Obr. 14: Coordinator brokerage

Definícia 24 Aktér (B) je *gatepeeker broker*, ak jeden z dvoch neprepojených aktérov (C) patrí do jednej skupiny (komunity), kým iný neprepojený aktér (A) patrí do rozdielnej skupiny (komunity). *Broker* tohto typu kontroluje prichádzajúce informácie a zdroje v rámci jeho skupiny (komunity) a robí rozhodnutia o tom, či majú alebo nemajú neprepojení aktéri v skupine (komunity) prístup k informáciám a zdrojom. Viď obrázok 15.



Obr. 15: Gatekeeper brokerage

Definícia 25 Aktér je *representative broker*, ak *broker* (B) a jeden nespojený aktér (A) patria do jednej skupiny (komunity), kým ten druhý nespojený aktér (C) patrí do inej rozdielnej skupiny (komunity), ale smer toku informácií alebo zdrojov je rozdielny. Viď obrázok 16.



Obr. 16: Representative brokerage

6.3.1 Identifikácia brokerage rolí

Päť typov *brokerage* rôl reprezentujú unikátne sociálne roly zapúzdzrujúce elementárny aspekt aktérovej štrukturálnej pozície v danej sieti. Jeden jednotlivec však môže zohrávať viac *brokerage* rolí naraz. Preto Gould & Fernandez [15] kvantifikovali celkovú participáciu jednotlivca v *brokerage* rolách pomocou *brokerage* skóra. Formálne definovali *brokerage* v grafe reprezentujúcom asymetrickú reláciu R : Nech a je *broker* medzi b a c iba ak bRa , aRc a $a\bar{R}c$, kde bRa indikuje, že b je prepojené s a reláciou R a $b\bar{R}c$ je negácia bRc . S touto definíciou, *brokerage* skóre sa vypočíta súčtom počtu koľko krát táto podmienka platí pre špecifickú kombináciu spojenia aktérov. To znamená, že ak nejaký aktér x zohráva pozíciu *coordinator* dva krát a pozíciu *representative* tri krát, tak aktér bude mať skóre pre pozíciu *coordinator* = 2, pre pozíciu *representative* = 3 a jeho celkové *brokerage* skóre bude 5.

Formalizácia *brokerage* rolí podľa Goula a Fernandez a je definovaná pre siete, v ktorých sú spojenia (hrany) orientované, čiže reprezentujúce vzťahy, pre ktoré môžeme rozlíšiť odosielateľa a prijímateľa. Keďže v mojej koncepcii siete, kde jednotlivé uzly sú členovia tímu a hrana medzi nimi je práve vtedy, keď medzi nimi prebehla konverzácia, moja vytvorená sieť je neorientovaná. Zovšeobecnenie na neorientovanú sieť je teda jasné; s takýmito dátami, každá hrana je považovaná za obojsmernú. Aj keď toto prináša jednu dôležitú zmenu originálnej formalizácie: v prípade neorientovaných vzťahov nemôžeme rozlíšiť rolu *gatepeeker* od roly *representative*, pretože neprítomnosť obojsmerných vzťahov redukuje tieto dve roly do jednej a *brokerage* skóre bude pre tieto dve roly identické. [23]

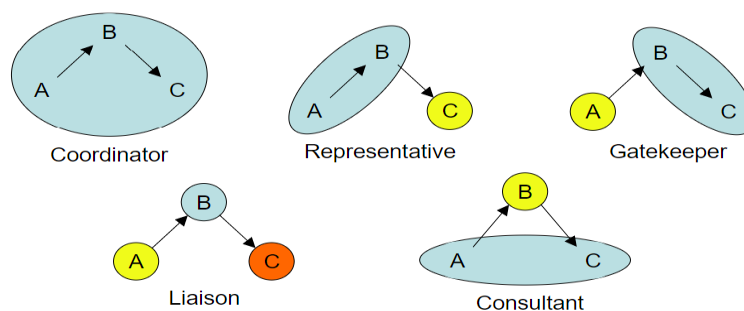
6.3.2 Popis metódy pre identifikáciu brokerage rolí

Podmienka pre detekovanie brokerage rolí je prítomnosť komunit. Pre každý uzol grafu si získam jeho susedné uzly. Tento uzol označujem ako B uzol. Potom prechádzam jeho susedné uzly každý s každým a kontrolujem, do akej komunity daný uzol patrí. Počas týchto priechodov označujem tieto uzly ako uzol A a uzol C a vyhodnocujem nasledovné podmienky:

1. Pokiaľ medzi uzlami A a C existuje hrana, preskočím ich a začínam priechod znova. Ak medzi nimi hrana nie je, prechádzam na podmienku 2.
2. Pokiaľ uzly B a A a C nepatria do jednej spoločnej komunity, uzol B je identifikovaný ako *Liaison* a navýši sa jeho skóre pre túto rolu.

3. Pokiaľ sú uzly A a C v rovnakej komunite a uzol B je v rozdielnej komunite, uzol B je detekovaný ako *Itinerant (Consultant)* a navýši sa jeho skóre pre túto rolu.
4. Pokiaľ sú uzly A a B , C v rovnakej komunite a uzol C je v inej komunite alebo ak sú uzly B a C v rovnakej komunite a uzol A je v inej komunite, uzol je detekovaný ako *Representative* a zároveň ako *Gatepeeker*, pretože nerozlišujem smer spojenia uzlov a teda im skóre navýšim zhodne.

Jeden uzol môže byť identifikovaný aj všetkými *brokerage* rolami. Keď je priechod všetkými uzlami dokončený, spočíta sa celkové skóre súčtom čiastkových skóre pre každú rolu.



Obr. 17: Identifikácie *brokerage* rolí [1]


6.4 Analýza ega

Analýza ego sietí sa stáva stále viac dôležitou s rastom sietí. Je oveľa jednoduchšie v obrovských sieťach analyzovať ego a jeho okolie ako celú sieť ako celok. Napríklad ak jeden človek má priemerne 5 blízkych osôb, potom v meste s populáciou desať tisíc ľudí bude päťdesiat tisíc priateľských väzieb. A ak by sme chceli študovať známosti? Riešením by bol výber podmnožiny obyvateľov mesta a ich *alter* uzlov.

Ďalšou odpoveďou na otázku, prečo študovať ego siete, je to, že niekedy nás nezaujíma sieť ako celok alebo komunity a podobne, ale zaujímajú nás dôležití alebo inak zaujímaví jednotlivci (lídri, umelci, tínedžeri a pod.) Sieť ega je zaujímavá, pretože je zdrojom informácií, sociálnej podpory, prístupu ku zdrojom, vplyvu a ďalších faktorov.

6.4.1 Veľkosť ego siete

Veľkosť ego siete je jednoduchá, ale veľavravná charakteristika. Definuje ju stupeň ego uzla, alebo teda počet *alter* uzlov ega. Hovorí o sociálnej podpore, prístupu k informáciám a zdrojom.[24]



Obr. 18: Velkosť ego = stupeň uzla: 6

6.4.2 Kompozícia ego siete

Čo sa týka kompozície ego siete, môžeme sledovať podobnosť medzi egom a jeho *alter* uzlami. Pre reprezentáciu podobnosti sa používa *homofília*. Môžeme predpokladať, že existuje vzťah medzi nejakým javom a tým, či ego zdieľa so svojimi *alter* uzlami nejakú vlastnosť (profesia, vzdelanie a pod.) Napríklad je prirodzené, keď niekto, kto zastáva pozíciu CFO (Chief Financial Officer) je obklopený ľuďmi, ktorí riešia financie alebo napríklad politici bývajú obklopení členmi rovnakej politickej strany.


Pre identifikáciu homofílie som využila prítomnosť komunit v sieti a použila som *Krackhardt-Sternov E-I index* [24].

$$\frac{E - I}{E + I} \quad (14)$$

- E je počet spojení s členmi inej skupiny (komunity) I je počet spojení s členmi rovnakej skupiny (komunity)
- nadobúda hodnoty od -1(homofília) do +1(heterofília)

6.4.3 Štruktúra ego siete

Štruktúrálna analýza sa opiera o informácie, či existujú alebo neexistujú spojenia medzi *alter* uzlami ego uzla. Princíp spočíva v tom, že nedostatok spojení medzi *alter* uzlami môže priniesť určité benefity samotnému egu. Tento princíp sa v analýze sociálnych sietí nazýva princíp štruktúrálnej diery (ang. *structural holes*). Medzi benefity, ktoré prinášajú štruktúrálné diery egu patria prístup k novým informáciám, moci alebo k slobode.



Obr. 19: Málo štrukturálnych dier vs. veľa štrukturálnych dier.

Koncept štrukturálnych dier je koncept analýzy sociálnych sietí vyvinutý R. S. Burtom. Predstavil tento pojem v snahe vysvetliť vznik rozdielov v sociálnom kapitále. Burtova teória naznačuje, že jednotlivci majú isté výhody alebo nevýhody podľa toho, ako sú zakotvené v spoločenských štruktúrach. Štrukturálna diera je chápaná ako medzera medzi dvoma jednotlivcami (chýbajúca hrana medzi uzlami), ktorí majú doplňujúce zdroje informácií. [25]


Efektívna veľkosť

Definícia 26 Efektívna veľkosť ego siete je

$$n - \frac{2t}{n} \quad (15)$$

kde $\frac{2t}{n}$ je redundancia siete, kde t je počet všetkých spojení v egocentrickej sieti (s výnimkou spojení k egu) a n je počet všetkých uzlov v egocentrickej sieti (s výnimkou ega). [26]

Efektívna veľkosť ego siete na obrázku 20 podľa definície 26 je rozdiel počtu *alter* uzlov ega a sumy ich redundancií a teda $6 - 1.33 = 4.67$. Efektívna veľkosť udáva počet neredundantných uzlov ego siete. [24]



Uzol G je ego	A	B	C	D	E	F	Celkom
Redundancia	3/6	2/6	0/6	1/6	1/6	1/6	1.33

Obr. 20: Príklad výpočtu redundancie

Čím viac je každý uzol odpojený od ostatných primárnych kontaktov, tým vyššia bude efektívna veľkosť. Tento indikátor nadobúda hodnoty od 1 (sieť poskytuje len jediné spojenie (hranu)) až do celkového počtu spojení, kedy každý kontakt (alter) je neredundantný. [24]

7 Aplikácia

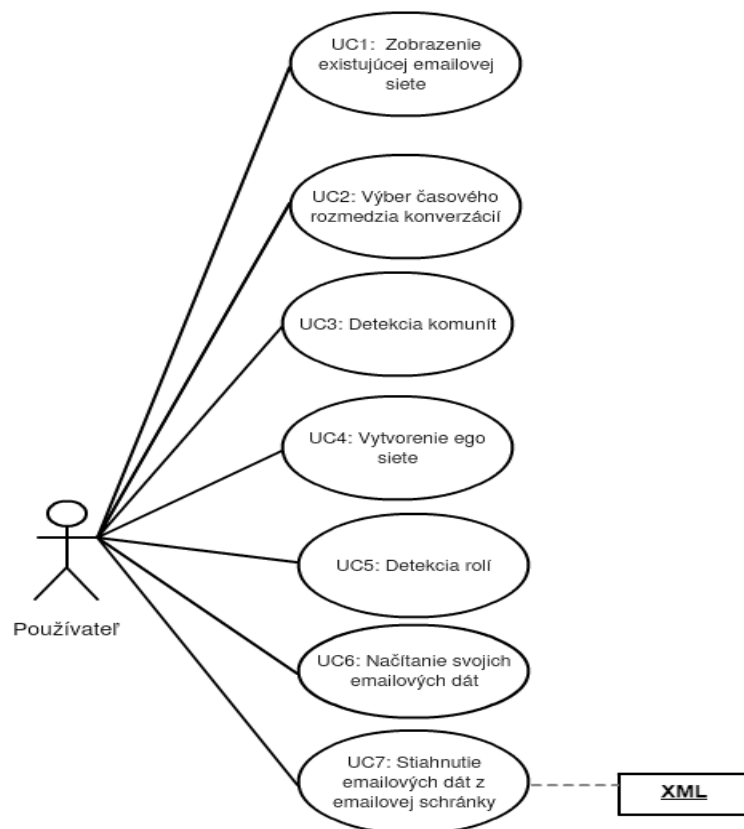
Táto kapitola obsahuje všetky podrobnosti o vývoji aplikácie, návrhu a ďalej špecifikáciách požiadavkov. Sú tu uvedené informácie o implementácii, návrhu, návrhových vzoroch, ale aj konštrukcii siete, predpríprave dát. Táto časť taktiež obsahuje diagramy najdôležitejších tried aplikácie alebo diagramy prípadov použitia.

7.1 Špecifikácia

Aplikácia slúži ako užívateľské rozhranie na analýzu emailovej komunikácie a vizualizáciu analytických výstupov. Aplikácia umožňuje exportovať dáta z emailovej schránky alebo importovať vlastný XML súbor s emailovými dátami a ďalej s týmito dátami pracovať a zobrazovať sieť emailovej komunikácie. Umožňuje vytvorenie ego-siete alebo detekovať vo vytvorenej sieti komunity. Najdôležitejšou časťou aplikácie je detekcia štrukturálnych rolí v sieti, čiže detekcia dôležitých a nedôležitých členov emailovej komunikácie a detekcia *brokerage* rolí.

7.1.1 Funkčné požiadavky


- Export dát z emailovej schránky
- Import vlastného XML súboru s emailovými dátami
- Zobrazenie informácií o emailovej sieti
- Vizualizácia emailovej siete
- Vytvorenie ego-siete
- Detekcia komunít
- Detekcia štrukturálnych rolí v sieti
- Výber časového rozmedzia emailových konverzácií
- Detekcia *brokerage* rolí



Obr. 21: UseCase Diagram

7.2 Návrh

Aplikácia je vytvorená ako .NET aplikácia (veria .NET Frameworku 4.6). Je vytvorená ako trojvrstvová, pre uloženie dát sa používa SQL databáza. Najnižšia vrstva aplikácie slúži na získavanie dát z databázy, pre prepojenie s databázou a posielanie dát z aplikácie do databázy používam Entity Framework a používam tu návrhový vzor Repository. Od tejto časti je oddelená časť s business logikou a na najvyššej časti, ktorá slúži len na zobrazenie dát a komunikáciu s užívateľom, používam známy prístup Model-View-Controller.

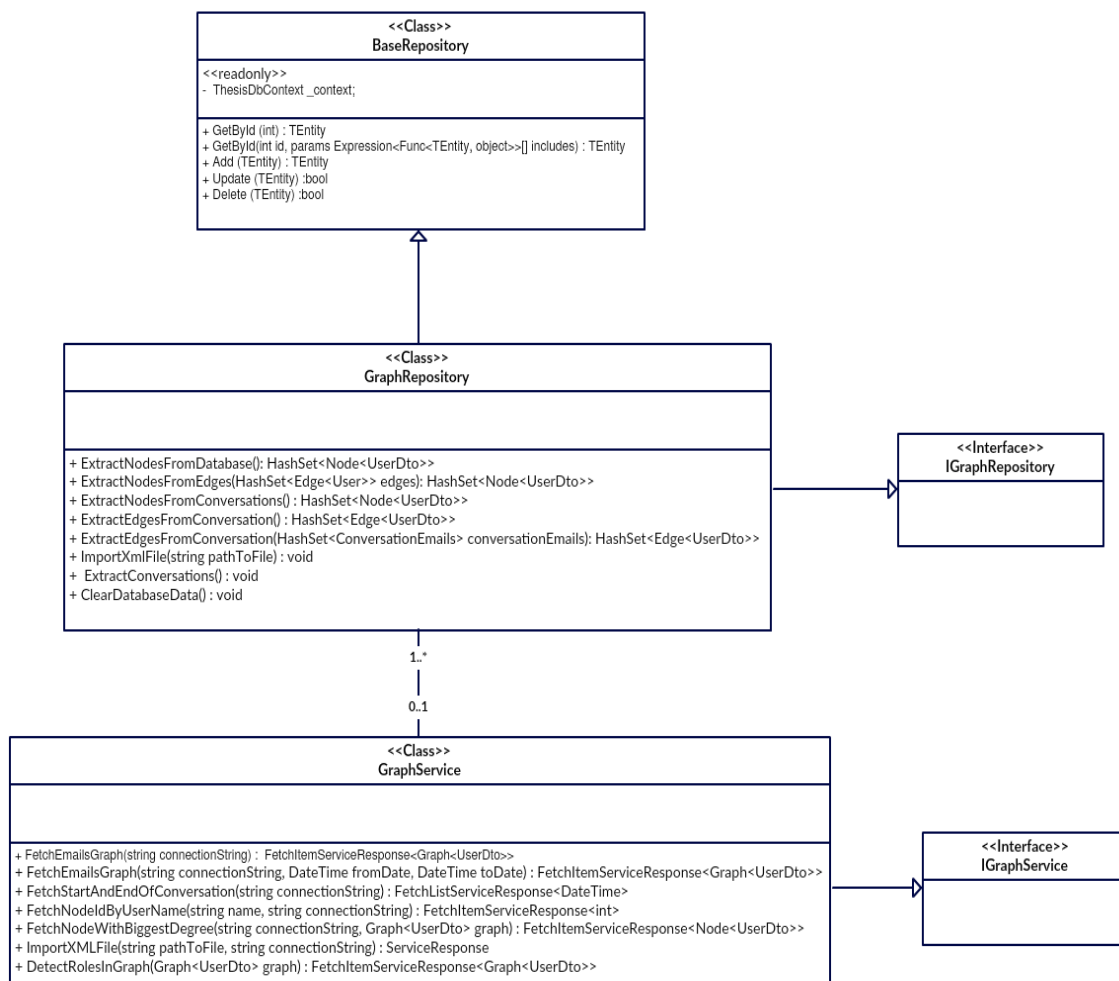


Obr. 22: Diagram komponent znázorňujúci jednotlivé komponenty architektúry aplikácie

7.2.1 Návrhové vzory

Repository [27]

Návrhový vzor Repository je základným kameňom doménou riadeného návrhu. Model aplikácie teda nemá poňatie o tom, akým spôsobom je realizovaná perzistencia. O to sa stará práve Repository. Navyiac práve vďaka tomu, že sa o persistenciu stará cudzí objekt, stačí poznať len jeho rozhranie a v prípade potreby ho ľahko nahradiť iným.




Obr. 23: Triedny diagram - Repository pattern

Model-View-Controller [28]

V aplikácii je použitý tradičný vzor Model View Controller (MVC). Je to jeden z najpoužívanějších a najobecnejších architektonických vzorov. MVC rozdeľuje program do troch hlavných častí:

- **Model** - dáta a súvisiace operácie
- **View** - prezentácia dát (užívateľské rozhranie), obsahuje priamy odkaz na model, aby mohol jeho dáta prezentovať vonkajšiemu svetu
- **Controller** - riadi tok udalostí v programe, konkrétne v tejto aplikácii kontrolery obsahujú len volanie metód z inej vrstvy aplikácie



Obr. 24: Model-View-Controller

7.3 Dôležité rozhodnutia

Pri navrhovaní aplikácie bolo potrebné urobiť niekoľko dôležitých rozhodnutí.

7.3.1 Dostupnosť dát

Pôvodne sa zvažovalo použitie aplikácie a analýzy dát nad verejne dostupnou anonymizovanou emailovou sadou. Emailových dát je ale veľmi málo a chcela som, aby sa výsledky práce dali overiť nie len inými analytickými nástrojmi, ale aj empiricky. Takže som využila to, že pracujem a moja emailová schránka teda nie je chudobná na maily. Navyše mi radi pomohli aj moji kolegovia a poskytli mi svoje emailové dáta. Takto som zozbierala reálne emailové dáta štyroch ľudí, o ktorých je známe ich postavenie v tíme alebo aj dátum nástupu do práce. Takže výsledky daných algoritmov som vedela porovnať s reálnou situáciou v kolektíve.


7.3.2 Webová vs. desktopová aplikácia

Bolo nutné sa rozhodnúť, či vyvíjať aplikáciu ako webovú alebo desktopovú. Ako platforma bola zvolená Microsoft .Net a programovací jazyk C#. Keďže doba ide dopredu a web a webové aplikácie sú stále viac používanéjšie a v súčasnosti existuje mnoho grafických knižníc pre vizualizáciu grafického rozhrania, rozhodla som sa aplikáciu vyvíjať ako webovú.

7.4 Použité knižnice

Vis.js

Vis.js je dynamická vizualizačná knižnica. Knižnica je navrhnutá tak, aby bola ľahko ovládateľná a aby mohla spracovať veľké množstvo dynamických dát a umožňovala manipuláciu s dátami a interakciu s nimi. Knižnica sa skladá z častí *DataSet*, *Timeline*, *Network*, *Graph2d* a *Graph3d*. Pre moju aplikáciu som používala len časť *Network*.



Obr. 25: Jednoduchá sieť vytvorená s použitím knižnice vis.js

```
<style type="text/css">
  #mynetwork {
    width: 600px;
    height: 400px;
    border: 1px solid lightgray;
  }
</style>

<script type="text/javascript">
  // create an array with nodes
  var nodes = new vis.DataSet([
    {id: 1, label: 'Node 1'},
    {id: 2, label: 'Node 2'},
    {id: 3, label: 'Node 3'},
    {id: 4, label: 'Node 4'},
    {id: 5, label: 'Node 5'}
  ]);

  // create an array with edges
  var edges = new vis.DataSet([
    {from: 1, to: 3},
    {from: 1, to: 2},
    {from: 2, to: 4},
    {from: 2, to: 5},
    {from: 3, to: 3}
  ]);

  // create a network
  var container = document.getElementById('mynetwork');
  var data = {
    nodes: nodes,
    edges: edges
  };
  var options = {};
  var network = new vis.Network(container, data, options);
</script>
```

Obr. 26: Príklad použitia knižnice vis.js

LouvainSharp

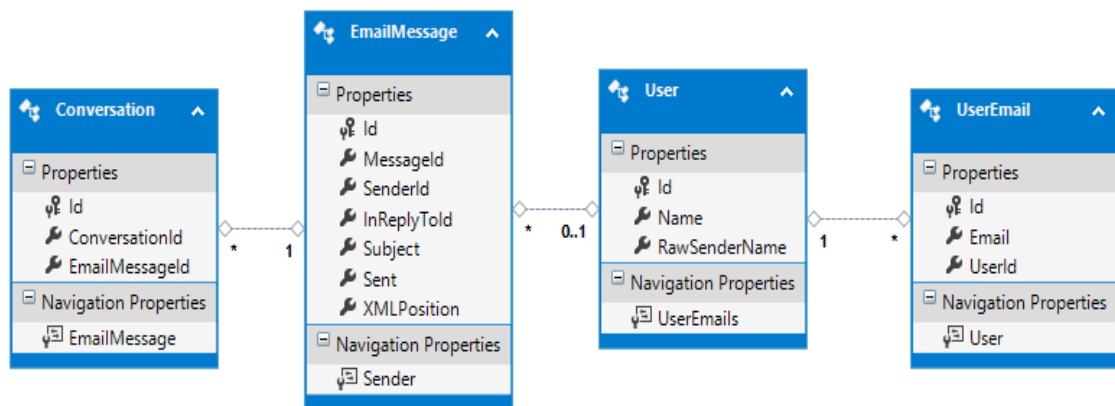
Ďalšou použitou knižnicou bola knižnica *LouvainSharp*, ktorá implementuje Louvainov algoritmus detekcie komúní v jazyku C#. Navyiac je knižnica paralelizovaná pomocou *plinq* pre maximalizáciu rýchlosti. [29]

Canvas.js

Ďalšou použitou grafickou knižnicou je knižnica *canvas.js*. Je to HTML5 knižnica, ktorá umožňuje responzívne vykresľovanie grafov. Táto knižnica bola použitá pre vykreslenie koláčového a stĺpcového grafu. [30]

7.5 Import dát

Do aplikácie je možné nahrať XML súbor, ktorý je spracovaný uloženou SQL procedúrou, ktorá rozparsuje emailové dáta na jednoduché entity - *User*, *EmailMessage*, *UserEmail* a *Conversation* a uloží ich do SQL databázy. S takto uloženými emailovými dátami používam pre import do aplikácie *Entity framework*, ktorý zaručuje prenos dát medzi aplikáciou a SQL databázou.



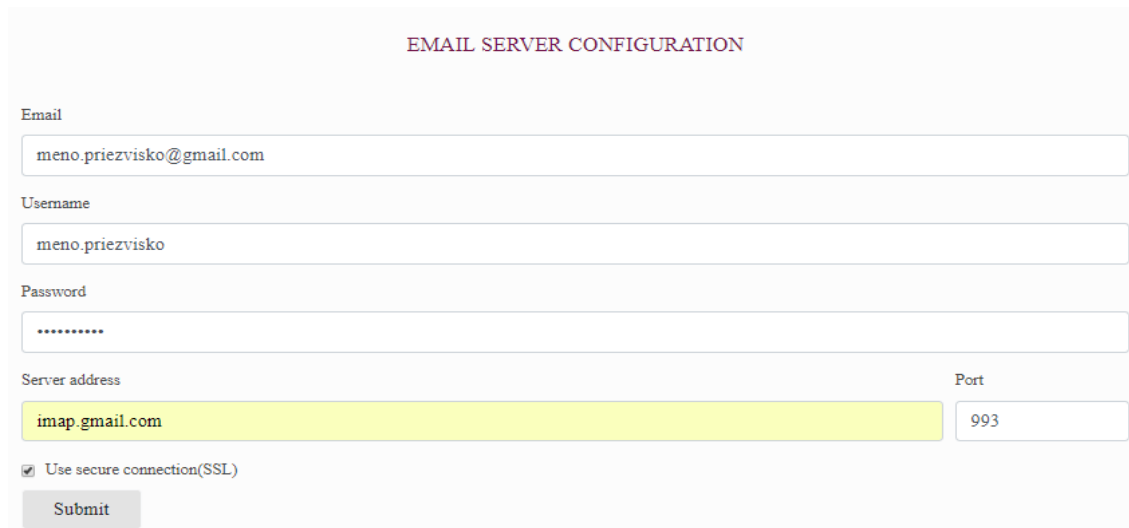
Obr. 27: Doménový model

7.6 Implementácia

Aplikácia je napísaná v jazyku C#, grafické rozhranie je naimplementované pomocou návrhového vzoru Model View Controller a graf bol vizualizovaný pomocou knižnice vis.js. Aplikácia bola vyvíjaná vo Visual Studiu 2017.

7.6.1 Metóda pre získanie emailových dát

Pre získanie emailových dát z emailovej schránky som naimplementovala metódu, ktorá sa pomocou protokolu IMAP pripojí na danú emailovú schránku a stiahne emaily vo forme XML súboru.



EMAIL SERVER CONFIGURATION

Email
meno.priezvisko@gmail.com

Username
meno.priezvisko

Password
.....

Server address
imap.gmail.com

Port
993

☒ Use secure connection(SSL)

Submit

Obr. 28: Príklad konfigurácie emailu pre získanie emailov

7.6.2 Konštrukcia siete

Rozdiel medzi prístupom rôznych štúdií a mojím prístupom pri konštrukcii grafu z emailového datasetu je v konštrukcii komunikačnej siete. Ako základnú stavebnú jednotku siete som si zvolila **konverzáciu**. Inšpirovala som sa prácou autorov Kudělka, Horák, Zehnaloová [7]. Konverzácia je teda súbor emailov, ktorá začína jediným emailom, obsahuje najmenej 2 emaily a dvoch rôznych odosielateľov. Vrcholom siete (grafu) sa teda stane užívateľ, ktorý bol ako odosielateľ aspoň v jednej takejto konverzácii. Hrana medzi užívateľmi je zostrojená medzi užívateľmi, ktorí boli spolu aspoň v jednej konverzácii ako odosielatelia. Výsledná sieť je neorientovaná a nevážená. Pre konverzáciu ešte ukladám čas jej začiatku, užívateľ si následne v aplikácii môže zvoliť časový rozsah konverzácií.

7.6.3 Konštrukcia ego siete

Pre algoritmus detekcie štrukturálnych rolí podľa SSRM bolo potrebné vytvoriť súvislú sieť. Aby sa sieť stala súvislou, vytváram ego sieť. Ego uzol si môže vybrať používateľ. Ego sieť vytváram tak, že k ego uzlu pridávam novú hranu ku každej nesúvislej komponente grafu tak, že ego tvorí hranu s uzlom, ktorý má v danej nesúvislej komponente najvyšší stupeň.

7.6.4 Triedy pre graf, vrcholy a hrany

Pre uloženie siete v pamäti slúži generická trieda `Graph<T>`. Vrcholy a hrany drží ako `Dictionary<int, HashSet<Node<T>>>`, čiže ako mapu vrcholov s ich susednými vrcholmi. Pre uloženie vrcholov a hrán grafu slúžia zoznamy hrán a vrcholov uložené ako `HashSet<Node<T> >` a `HashSet<Edge<T>>`. Trieda je generická preto, aby bolo možné vytvoriť graf pre rôzne entity. Triedy reprezentujúce vrcholy a hrany sú tiež generické a predstavujú ich `Node<T>` a `Edge<T>`. Pre identifikáciu komunity, bola vytvorená trieda `Comunity<T>`.

8 Experimenty

V tejto kapitole popisujem experimenty, ktoré som previedla nad rôznymi emailovými sadami vo vytvorenej aplikácii. Popisujem prípravu a import dát, ďalej vizualizáciu jednotlivých datasetov a tiež výsledky a porovnanie vybraných analytických metód. V prvej časti popisujem analýzu agregovanej sady ako celkovú analýzu emailovej komunikácie tímu a v druhej časti popisujem analýzu emailovej komunikácie jednotlivca.

Poznámka: Z dôvodu ochrany osobných údajov sú všetky mená osôb a domén anonymizované.

8.1 Analýza emailovej komunikácie tímu

Analýzu emailovej komunikácie tímu som previedla na agregovanej emailovej sade, ktorá obsahuje emaily od štyroch jednotlivcov. Základné informácie o tomto datasete sú uvedené v tabuľke.

	počet
Emaily	21738
Konverzácie	4149
Poživatelia	370
Používatelia, ktorí sú aspoň v jednej konverzácii	273
Emaily poslané z pracovného emailu	20367

Tabuľka 1: Základné informácie o datasete

8.1.1 Príprava a import dát

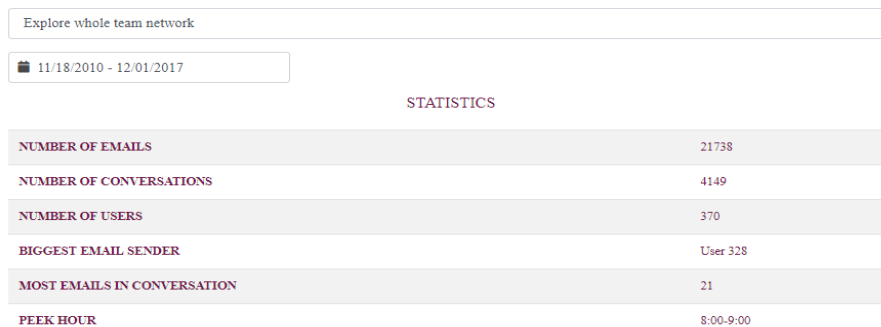
Ako už bolo spomenuté, pre samotnú analýzu som nepoužila žiadny verejne dostupný dataset, ale použila som svoju emailovú sadu a emailové sady od mojich troch kolegov z práce. V dobe, keď som od nich emaily požadovala, moja aplikácia ešte nebola hotová a tak sa pre získanie ich emailov použila externá aplikácia *TeamNet Data* [31]. Emailové sady boli poskytnuté v súbore formátu XML.

Keďže sme kolegovia a pracujeme spolu v tíme, nachádzali sme sa viac krát v rovnakej emailovej reťazi, takže sa v sadách vyskytovali emaily duplikátne. Pre spracúvanie emailov som vytvorila SQL procedúru, ktorá jednotlivé XML súbor načíta, rozdelí emaily, používateľov a konverzácie na jednotlivé entity a naimportuje ich do SQL databázy. Pre odstránenie duplikátov som použila SQL skript, ktorý zaručil odstránenie duplikátnych položiek.

Po spustení aplikácie mám na výber stiahnuť si svoj XML súbor o svojej emailovej schránky, naimportovať ho do aplikácie a ďalej prezeráť svoje emailové dáta. Keďže emailové sady som už mala predpripravené, mohla som postupovať priamo k vizualizácii a analýze.


8.1.2 Vizualizácia datasetu

Aplikácia umožňuje výber vizualizácie jednotlivých členov tímu a tiež celého tímu celkovo. S výberom daného datasetu sa pre danú sieť zobrazia aj základné informácie ako počet emailov, odosielateľov emailov, najpoužívanějšíe emailové domény a podobne.



Obr. 29: Základné informácie o tímovej sieti.


Na obr. 29 sú zobrazené základné informácie o agregovanej sieti. Štyria sme celkovo napísali 21738 emailov z toho bolo detekovaných 4149 konverzácií. Celkovo sa na emailovej komunikácii podieľalo 370 používateľov. Najviac emailov v agregovanej sade poslal používateľ *User 328*. Hodina, kedy sa posielalo celkovo najviac emailov bola medzi ôsmou a deviatou hodinou ráno, čiže to je čas, kedy ľudia prídu do práce a prvé, čo urobia je, že si skontrolujú emaily.



Obr. 30: Najviac používané emailové domény.

Na obr. 30 sú zobrazené emailové domény, z ktorých používatelia najviac posielali emaily. Najviac emailov sa poslalo z domén, ktoré sú oficiálne domény spoločnosti, v ktorej pracujem. Ostatné domény patria zákazníkom, s ktorými ako spoločnosť spolupracujeme.

Na obr. 31 je vizualizácia celkovej siete tímu v základnej podobe.




Obr. 31: Vizualizácia siete.

8.1.3 Detekcia komunít

Aplikácia umožňuje detekovať komunity v sieti a následne ich vizualizovať. Pre ďalšiu analýzu poskytujem v nasledujúcej tabuľke základné informácie o členoch tímu. Pre analýzu komunít využívam to, že každý nastúpil do práce v iný rok, takže na prelome týchto rokov by mal byť zaznamenaný nárast komunít.

Meno	Aktuálna pozícia	Dátum nástupu do firmy
Člen tímu 1	Test engineer	1.7.2011
Člen tímu 2	Junior Developer	1.9.2016
Člen tímu 3	Medior Developer	1.6.2017
Člen tímu 4	Lead Developer	1.11.2010

Tabuľka 2: Informácie o členoch tímu



Obr. 32: Vizualizácia komunít v tímovej sieti za celkový čas

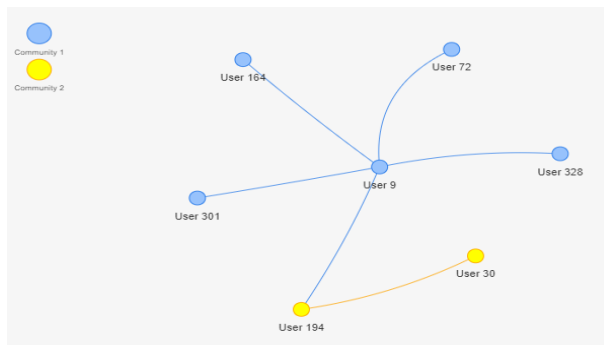
Celkovo bolo v sieti detekovaných 13 komunít. Najväčšia komunita má 57 uzlov, najmenšia má 2 uzly. Celkové zloženie komunít je zobrazené na nasledujúcom obrázku.

COMMUNITIES	
Community 1	48 nodes
Community 2	57 nodes
Community 3	35 nodes
Community 4	56 nodes
Community 5	19 nodes
Community 6	3 nodes
Community 7	14 nodes
Community 8	23 nodes
Community 9	3 nodes
Community 10	2 nodes
Community 11	5 nodes
Community 12	2 nodes
Community 13	6 nodes

Obr. 33: Rozloženie komunít v tímovej sieti za celkový čas

8.1.3.1 Zmeny komunít v čase

Zmeny komunít som zaznamenávala v dátumoch, kedy jednotliví členovia tímu nastupovali do práce. Prvým časovým úsekom, ktorý som sledovala bolo obdobie medzi 1.11.2010 - 1.7.2011, kedy bol zamestnancom spoločnosti zatiaľ len jeden z nás. Boli detekované dve komunity, rozloženie uzlov je zobrazené na obrázku 34



Obr. 34: Rozloženie komunít za prvý časový úsek

Ďalší interval, ktorý som zvolila bol interval medzi 1.11.2010 - 31.8.2016, ktorý reprezentuje čas, kedy boli zamestnancami dvaja z nášho tímu. Detekovaných bolo 9 komunít.

COMMUNITIES	
Community 1	42 nodes
Community 2	18 nodes
Community 3	40 nodes
Community 4	29 nodes
Community 5	3 nodes
Community 6	9 nodes
Community 7	2 nodes
Community 8	2 nodes
Community 9	5 nodes

Obr. 35: Rozloženie komunít za druhý časový úsek

Do príchodu ďalšieho kolegu (interval 1.11.2010 - 31.5.2017) bolo detekovaných 12 komunít, čiže mojim príchodom do firmy pribudli tri komunity, to znamená že príchodom ďalšieho kolegu počet komunít vzrástol o jednu komunitu. Na ďalšom obrázku je zobrazené rozloženie komunít v treťom intervale.

COMMUNITIES	
Community 1	46 nodes
Community 2	44 nodes
Community 3	27 nodes
Community 4	27 nodes
Community 5	21 nodes
Community 6	19 nodes
Community 7	3 nodes
Community 8	24 nodes
Community 9	3 nodes
Community 10	2 nodes
Community 11	2 nodes
Community 12	6 nodes

Obr. 36: Rozloženie komunit za tretí časový úsek

8.1.4 Ego sieť

Pre analýzu ego siete som vybrala troch jednotlivcov, z ktorých som vytvorila ego uzol a vytvorila pre nich ego sieť. Porovnávala som jednotlivé miery a počet komunit, ktoré spájali. Vyberala som uzly s rozdielnou centralitou, aby som mohla sledovať porovnanie medzi výsledkami. Porovnanie je možné vidieť v tabuľke.

	Stupeň uzla	Počet prepojených komunit	Efektívna veľkosť	E-I index
Aktér 1	129	13	127	0.52
Aktér 2	81	11	72	0.06
Aktér 3	20	11	18	0.4

Tabuľka 3: Informácie o vytvorenej ego sieti

Podľa veľkosti, čiže stupňa uzla môžem povedať, že uzol s veľkosťou 129 bude mať určite väčší sociálnu podporu od ostatných aktérov v sieti, väčší prísun k zdrojom a informáciám v porovnaní s uzlami s veľkosťou 81 alebo 20. Čo sa týka počtu prepojených komunit sú ale títo aktéri na tom podobne a spájajú porovnateľné množstvo komunit. Podľa E-I indexu môžem povedať, že ego sieť každého aktéra je heterofilna a tak sa v svojej práci stretávajú so širokou škálou ľudí, nielen s ľuďmi z podobného okolia.

8.1.5 Analýza rolí

Analýzu rolí som prevádzala na sieti s vytvoreným ego uzlom (ako ego uzol som zvolila uzol s najväčším stupňom).

8.1.5.1 SSRM

V na obr. 37 sú zobrazené počty detekovaných štrukturálnych rôľ v sieti. Uzly, ktoré boli de-

tekované ako *leader* zastávajú v reálnom živote pozíciu *Lead developer*, *Tester*, *Product owner*, *HR manager*, *Project manager*, *Sales manager*, *IT Consultant* a ďalší *Project manager*. Žiadny uzol nebol detekovaný ako *Mediator*. Tri uzly boli detekované ako *Outermost*, čo majú byť menej dôležití jedinci a naozaj som sa s nimi ani s ich menom v práci nestretla.

SSRM Roles

Leader	8
Mediator	0
OuterMost	3
OuterMost	0

Obr. 37: Počet detekovaných štrukturálnych rôl


8.1.5.2 Brokerage

V na obr. 38 a 40 je zobrazených desať najväčších *broker* aktérov v sieti spolu s grafom ich čiatkovým skóre pre každú *brokerage* rolu, ako aj celkové *brokerage* skóre.

TOP 10 BROKERS

	Name	Coordinator	Itinerant	Gatekeeper	Representative	Liaison	Total
1	USER 328	976	1758	6166	6166	6646	21712
2	USER 13	1084	404	2708	2708	744	7648
3	USER 334	498	12	420	420	26	1376
4	USER 9	460	14	408	408	40	1330
5	USER 117	116	130	480	480	0	1206
6	USER 141	162	20	416	416	72	1086
7	USER 27	344	6	326	326	40	1042
8	USER 349	44	54	324	324	210	956
9	USER 116	506	0	110	110	4	730
10	USER 146	204	6	176	176	20	582

Obr. 38: Desať aktérov s najväčším *brokerage* skórom



Obr. 39: Desať aktérov s najväčším *brokerage* skórom - graf

8.2 Analýza jednotlivca

V tejto časti popisujem analýzu jednotlivca od získania emailových dát z emailového účtu, importu do aplikácie a zobrazenie výsledkov metód v aplikácii. Pre analýzu jednotlivca používam svoju emailovú sadu pre demonštrovanie získavania a importu emailov.

8.2.1 Príprava a import dát


Pre získanie emailových dát z emailovej schránky používam navrhnutú aplikáciu. Po zadaní emailového účtu, používateľského mena, hesla, adresu servera a portu získam XML súbor s emailami, ktorý nainportujem do aplikácie a zobrazí sa mi moja emailová sieť.



Obr. 40: Analýza jednotlivca - základná vizualizácia

8.2.2 Informácie o datasete

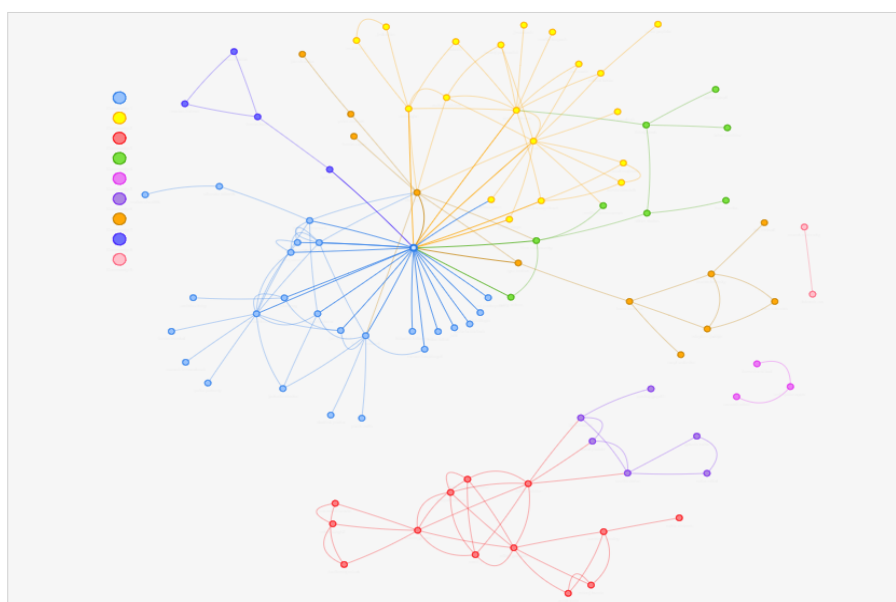
Spolu s vizualizáciou datasetu sa zobrazia aj základné štatistiky o datasete. Moja emailová schránka obsahuje 3135 emailov, ktoré napísalo 155 používateľov a bolo detekovaných 512 konverzácií. Osoba, ktorá napísala najviac emailov bol používateľ, ktorý zastáva pozíciu *Project manager*. Hodina, kedy sa písalo najviac emailov bola medzi siedmou a ôsmou hodinou ráno. Celkový sumár spolu s najpoužívanějšími emailovými doménami je na obrázku 42.



Obr. 41: Analýza jednotlivca - základné štatistiky

8.2.3 Detekcia komúní

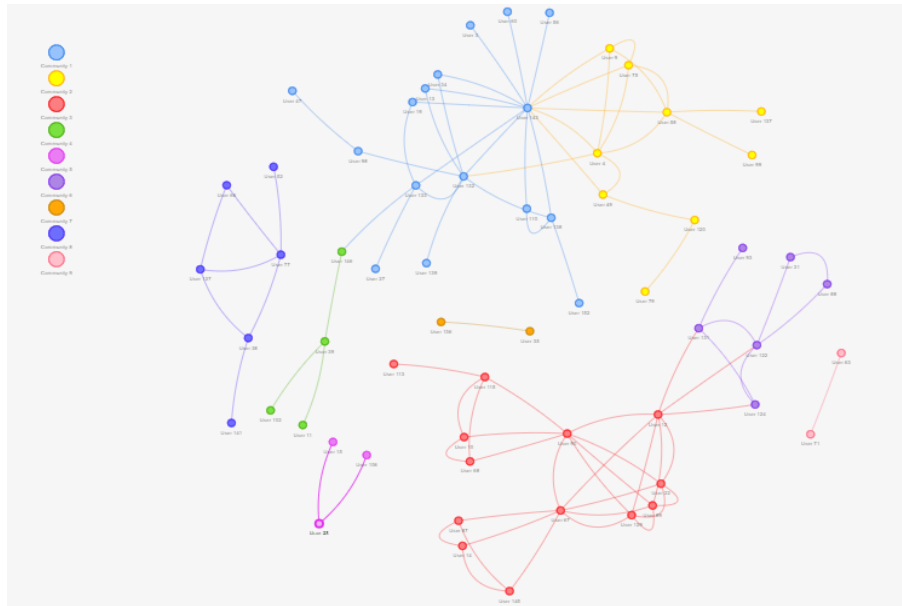
Celkovo bolo v datase detekovaných 9 komúní. Najväčšia komunita obsahuje 26 uzlov, najmenšia komunita obsahuje 2 uzly.



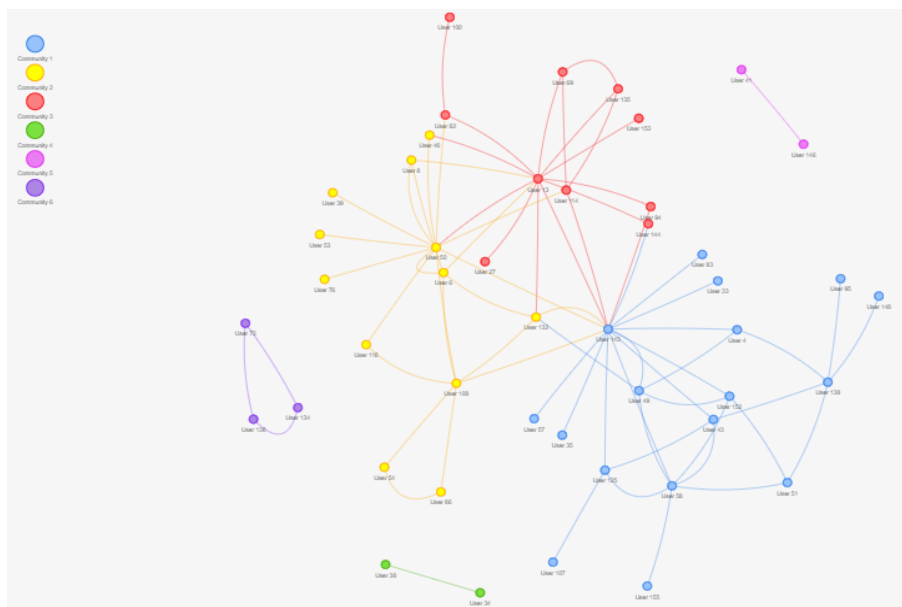
Obr. 42: Analýza jednotlivca - vizualizácia komúní

8.2.3.1 Zmeny komunit v čase

Pre zmeny komunit v čase som využila obdobia, kedy som pracovala na iných projektoch a teda sa komunity môžu v týchto intervaloch líšiť. Obdobie prvého projektu je v intervale od 1.9.2016 do 1.3.2017 a obdobie druhého je od 1.3.2017 do súčasnej doby, povedzme do 31.3.2018.



Obr. 43: Analýza jednotlivca - vizualizácia komunit v prvom časovom intervale



Obr. 44: Analýza jednotlivca - vizualizácia komunit v druhom časovom intervale

Ako vidieť na obrázkoch 43 a 44 zloženie komunit sa líši, či už zložením jednotlivých uzlov, tak aj veľkosťou a počtom, čo je samozrejme prirodzené, keďže som komunikovala v týchto

intervaloch s inými osobami. V prvom intervale bolo detekovaných 9 komunít, najväčšia komunita mala 16 uzlov, najmenšia 2 uzly. Čo sa týka druhého intervalu, bolo detekovaných 6 komunít, najväčšia komunita obsahovala 17 uzlov najmenšia rovnako 2 uzly.

8.2.4 Ego sieť

Pre analýzu ega som vybrala cielene troch jednotlivcov zo siete, ktorí pracujú na rozdielnej pozícii. Vybrala som jedného developera, jedného projektového manažéra a testera. Z každého z nich vytváram v sieti ego a v nasledujúcej tabuľke porovnávam ich silu v sieti.

Aktér	Pozícia	Prepojené komunity	Efektívna veľkosť	E-I index
Aktér 1	developer	8	28	-0.06
Aktér 2	projektový manažér	9	15	-0.25
Aktér 3	tester	4	5	0

Tabuľka 4: Informácie o vytvorenej ego sieti

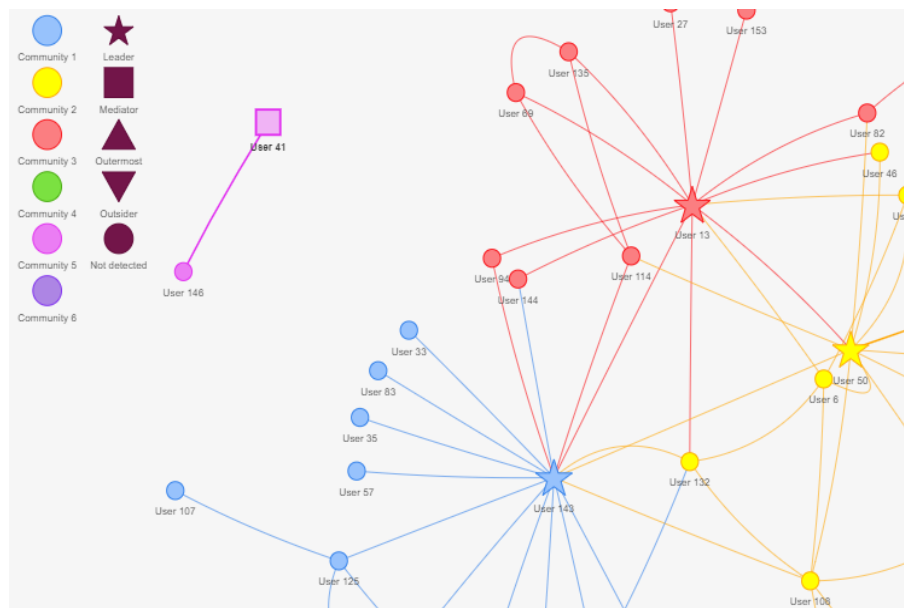
Podľa pozície by sme mohli predpokladať, či daný aktér spája viac alebo menej komunít, pretože projektový manažér sa určite vo svojej práci stretáva s rôznorodejšími osobami ako tester alebo developer. To ukázala aj analýza ega, kedy projektový manažér ako ego spája všetkých 9 komunít, kým tester len 4 komunity. Tiež sa líši efektívna veľkosť, ktorá udáva počet neredundantných uzlov. Kým developer má 28 nerundantných uzlov, projektový manažér má len 15, čo môže znamenať, že v reálnom svete projektový manažér môže čerpať informácie cez rôzne iné uzly, kým developer sa sústreďí na najbližšie spojky. E-I index udáva, že ego siete sú homofilne a teda aktéri v tomto datasete komunikovali výlučne s ľuďmi v ich komunite.

8.2.5 Analýza rolí

Analýzu rolí som prevádzala na sieti s detekovaným ego uzlom, ktorý som zvolila podľa najväčšieho stupňa uzla.

8.2.5.1 SSRM

Analýza štrukturálnych rolí dopadla podľa očakávaní. Boli detekované tri uzly s rolou *leader* a jeden uzol s rolou *mediator*. Uzly detekované ako *leader* pracujú na pozíciách *Project Manager*, *Product owner* a *Developer*. Možno trochu nezvyčajné je, že mňa ako developera môj algoritmus identifikoval ako *leader* rolu. Keď to premietnem do reálneho života, kde je v tíme jediná žena, môžem povedať, že táto detekcia dáva zmysel.




Obr. 45: Analýza jednotlivca - detail detekovaných SSRM rolí

8.2.5.2 Brokerage

V na obr. 46 a 47 je zobrazených desať najväčších *broker* aktérov v sieti spolu s grafom ich čiatkovým skórom pre každú *brokerage* rolu, ako aj celkové *brokerage* skóre.

TOP 10 BROKERS							
	Name	Coordinator	Itinerant	Gatepeeker	Representative	Liaison	Total
1	USER 143	76	10	138	138	18	380
2	USER 13	40	10	78	78	6	212
3	USER 50	50	4	56	56	2	168
4	USER 108	22	0	8	8	0	38
5	USER 58	28	0	0	0	0	28
6	USER 138	20	0	0	0	0	20
7	USER 132	0	0	8	8	2	18
8	USER 49	4	0	6	6	0	16
9	USER 114	0	0	8	8	0	16
10	USER 6	6	0	2	2	0	10

Obr. 46: Desať aktérov s najväčším *brokerage* skórom



Obr. 47: Desat aktérov s najväčším *brokerage* skórom - graf

Používatelia, ktorí boli detekovaní ako *broker* jednotlivci, zastávajú vo firme pozície ako *Asistent*, *Lead developer*, *Product owner*, *Consultant* alebo *Marketing specialist*.

9 Záver

Práca splnila všetky zadané ciele. Boli naštudované rešerše obdobných riešení a analytických prístupov a vybrané metódy analýzy sietí vhodné pre analýzu emailovej komunikácie. Na tomto základe bolo navrhnuté používateľské rozhranie pre analýzu emailovej komunikácie a vizualizáciu analytických výstupov. Toto používateľské rozhranie umožňuje získavanie emailových správ z vybraného zdroja, import týchto alebo inak získaných dát, vizualizáciu a zobrazenie výsledkov jednotlivých metód pre analýzu emailovej komunikácie. Aplikácia umožňuje zobrazenie základných informácií o emailovej komunikácii, vizualizáciu siete, detekciu komunit, tvorbu ego siete, detekciu štrukturálnych rolí a detekciu *brokerage* rolí v emailovej sieti. Následne boli uvedené experimenty analýzy emailovej komunikácie tímu a emailovej komunikácie jednotlivca.

9.1 Možnosti rozšírenia a zdokonalenia práce

9.1.1 Možné rozšírenia aplikácie

Vizualizácia veľkých grafov

Využitelnosti aplikácie by pomohlo, keby vedela vizualizovať aj rádovo väčšie grafy. So zobrazovaním rozsiahlych grafov sa v práci nepočítalo a už pri zobrazovaní emailov celého tímu nebolo pole pre vykreslenie grafu dostačujúce, čo bolo limitované aj knižnicou *vis.js*.

Viac možností filtrovania

V aplikácii môže používateľ filtrovať emailovú komunikáciu podľa času. Mohlo by byť užitočné nastavenie filtru aj podľa iného kritéria. Napríklad odfiltrovať jednotlivých používateľov podľa pracovnej pozície, filtrovanie podľa stupňa vrcholu uzla alebo filtrovanie podľa pohlavia.

Zobrazenie viac informácií o hranách a vrchoch

Aplikácia umožňuje zobraziť po prejdení myšou na vrchol informácie o stupni daného vrcholu. Pri analýze grafu ako takom by bolo dobré rozšíriť tieto informácie o ďalšie miery a meriky a iné charakteristiky siete, ako napríklad closeness centrality či betweenness centrality.

Literatúra

- [1] “Steve borgatti: Brokerage.” <http://www.analytictech.com/Essex/Lectures/Brokerage.pdf>.
- [2] J. Diesner, T. L. Frantz, and K. M. Carley, “Communication networks from the enron email corpus “it’s always about the people. enron is no different”,” *Computational & Mathematical Organization Theory*, vol. 11, no. 3, pp. 201–228, 2005.
- [3] X. Fu, S.-H. Hong, N. S. Nikolov, X. Shen, Y. Wu, and K. Xuk, “Visualization and analysis of email networks,” in *Visualization, 2007. APVIS’07. 2007 6th International Asia-Pacific Symposium on*, pp. 1–8, IEEE, 2007.
- [4] A. Chapanond, M. S. Krishnamoorthy, and B. Yener, “Graph theoretic and spectral analysis of enron email data,” *Computational & Mathematical Organization Theory*, vol. 11, no. 3, pp. 265–281, 2005.
- [5] G. Tang, J. Pei, and W.-S. Luk, “Email mining: tasks, common techniques, and tools,” *Knowledge and Information Systems*, vol. 41, no. 1, pp. 1–31, 2014.
- [6] A. Abnar, M. Takaffoli, R. Rabbany, and O. R. Zaïane, “Ssrn: structural social role mining for dynamic social networks,” *Social Network Analysis and Mining*, vol. 5, no. 1, p. 56, 2015.
- [7] S. Zehnalova, Z. Horak, and M. Kudelka, “Email conversation network analysis: Work groups and teams in organizations,” in *Advances in Social Networks Analysis and Mining (ASONAM), 2015 IEEE/ACM International Conference on*, pp. 1262–1268, IEEE, 2015.
- [8] “Do millennial and gen z consumers still use email?” <https://www.bluecore.com/blog/do-millennials-use-email/>. Navštívené: 2017-03-30.
- [9] P. Kovář, “Úvod do teorie grafů,” *Vysoká škola báňská. Technická univerzita. Ostrava*, 2012.
- [10] J. Demel, *Grafy a jejich aplikace*. Academia, 2002.
- [11] V. D. Blondel, J.-L. Guillaume, R. Lambiotte, and E. Lefebvre, “Fast unfolding of communities in large networks,” *Journal of statistical mechanics: theory and experiment*, vol. 2008, no. 10, p. P10008, 2008.
- [12] M. E. Newman, “The structure and function of complex networks,” *SIAM review*, vol. 45, no. 2, pp. 167–256, 2003.
- [13] A.-L. Barabási, *Network science*. Cambridge university press, 2016.
- [14] R. D. Luce and A. D. Perry, “A method of matrix analysis of group structure,” *Psychometrika*, vol. 14, no. 2, pp. 95–116, 1949.

- [15] G. W. Flake, S. Lawrence, and C. L. Giles, “Efficient identification of web communities,” in *Proceedings of the sixth ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 150–160, ACM, 2000.
- [16] F. Radicchi, C. Castellano, F. Cecconi, V. Loreto, and D. Parisi, “Defining and identifying communities in networks,” *Proceedings of the National Academy of Sciences of the United States of America*, vol. 101, no. 9, pp. 2658–2663, 2004.
- [17] V. D. Blondel, J.-L. Guillaume, R. Lambiotte, and E. Lefebvre, “Fast unfolding of communities in large networks,” *Journal of statistical mechanics: theory and experiment*, vol. 2008, no. 10, p. P10008, 2008.
- [18] N. Crossley, E. Bellotti, G. Edwards, M. G. Everett, J. Koskinen, and M. Tranmer, *Social network analysis for ego-nets: Social network analysis for actor-centred networks*. Sage, 2015.
- [19] R. V. Gould and R. M. Fernandez, “Structures of mediation: A formal approach to brokerage in transaction networks,” *Sociological methodology*, pp. 89–126, 1989.
- [20] P. V. Marsden, “Brokerage behavior in restricted exchange networks,” *Social structure and network analysis*, vol. 7, no. 4, pp. 341–410, 1982.
- [21] R. S. Burt, *Structural holes: The social structure of competition*. Harvard university press, 2009.
- [22] K. Stovel and L. Shaw, “Brokerage,” *Annual Review of Sociology*, vol. 38, pp. 139–158, 2012.
- [23] E. S. Spiro, R. M. Acton, and C. T. Butts, “Extended structures of mediation: Re-examining brokerage in dynamic networks,” *Social Networks*, vol. 35, no. 1, pp. 130–143, 2013.
- [24] R. DeJordy and D. Halgin, “Introduction to ego network analysis,” *Boston MA: Boston College and the Winston Center for Leadership & Ethics*, 2008.
- [25] R. S. Burt, “Structural holes and good ideas,” *American journal of sociology*, vol. 110, no. 2, pp. 349–399, 2004.
- [26] S. P. Borgatti, “Structural holes: Unpacking burt’s redundancy measures,” *Connections*, vol. 20, no. 1, pp. 35–38, 1997.
- [27] “Active Record vs. Repository pattern repository pattern.” <https://www.rarous.net/weblog/271-active-record-vs-repository-pattern.aspx>. Navštívené: 2018-01-15.
- [28] “Model view controller.” <http://voho.eu/wiki/model-view-controller/>. Navštívené: 2017-01-25.

- [29] “Louvainsharp - fast louvain method of community detection in c#.” <http://www.markusmobius.org/software/louvainsharp-fast-louvain-method-community-detection-c>. Navštívené: 2017-12-12.
- [30] “Canvas.js.” <https://canvasjs.com/>. Navštívené: 2018-04-20.
- [31] “TeamNET data.” <http://inflex.cz:8075/TeamNETdata>. Navštívené: 2017-09-30.

10 Prílohy

Súčasťou diplomovej práce je CD, ktorého súčasťou je:

1. zdrojový kód aplikácie
2. použité datasety
3. SQL skripty